

A Linear Non-Gaussian Acyclic Model for Causal Discovery

Modelos Gráficos Causales

Sebastián Bejos

8 de julio de 2019

Instituto Nacional de Astrofísica Óptica y Electrónica

En este trabajo se muestra cómo descubrir la **estructura causal completa** de datos de valores continuos, bajo los siguientes supuestos:

- (a) El proceso de generación de datos es **lineal**,
- (b) No hay **co-factores no observados** y
- (c) Las variables de perturbación tienen distribuciones **no-Gaussianas** de varianza no cero.

- Cuando se **omite** el supuesto de que los datos siguen una **distribución normal** se logra una **ventaja significativa**.
- Mientras el enfoque **lineal-Gaussiano** generalmente solo conduce a un **conjunto de modelos posibles**, equivalentes en su estructura de correlación condicional.
- Un enfoque **lineal-no-Gaussiano** permite estimar el **modelo causal completo, sin parámetros indeterminados**.

Se asume que los datos observados son generados por un proceso con las siguiente propiedades:

- Las variables observadas $x_i, i \in \{1, \dots, m\}$ se pueden ordenar de tal forma que las variables no causen ninguna variable anterior en el orden.
- Se le llama **orden causal** a tal orden y se denota por $k(i)$.

- El valor asignado a cada variable x_i es una **función lineal** de los valores ya asignados a las variables anteriores, más un término 'perturbación' (ruido) e_i , y más un término constante opcional c_i , es decir

$$x_i = \sum_{k(j) < k(i)} b_{ij} x_j + e_i + c_i$$


- Las perturbaciones e_i son todas variables aleatorias continuas con **distribuciones no Gaussianas** de **varianzas diferente de cero**, y las e_i son **independientes entre sí**, es decir,

$$P(e_1, \dots, e_m) = \prod_i P_i(e_i).$$

- Un modelo con estas tres propiedades se le llama un modelo **lineal, no gaussiano, acíclico**, abreviado **LiNGAM**.

- Suponemos que podemos observar una gran cantidad de vectores de datos \mathbf{x} (que contienen los componentes x_i)
- Cada uno de estos vectores \mathbf{x} se genera de acuerdo con el proceso descrito anteriormente:
 1. Con el mismo orden causal $k(i)$,
 2. Los mismos coeficientes b_{ij} ,
 3. Las mismas constantes c_i y
 4. Las perturbaciones e_i se muestrean independientemente sobre la misma distribución.

Redes Lineales Causales



$$x_4 = e_4$$

$$x_2 = 0.2x_4 + e_2$$

$$x_1 = x_4 + e_1$$

$$x_3 = -2x_2 - 5x_1 + e_3$$

Identificación del Modelo utilizando ICA

- En notación matricial el modelo LiNGAM

$$x_i = \sum_{k(j) < k(i)} b_{ij} x_j + e_i$$

puede ser escrito como:

$$\mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{e} \tag{1}$$

$$\begin{bmatrix} x_4 \\ x_2 \\ x_1 \\ x_3 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0.2 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & -2 & -5 & 0 \end{bmatrix} \begin{bmatrix} x_4 \\ x_2 \\ x_1 \\ x_3 \end{bmatrix} + \begin{bmatrix} e_4 \\ e_2 \\ e_1 \\ e_3 \end{bmatrix}$$

Análisis de Componentes Independientes (ICA)

- El **modelo ICA** para las variables observables X_i con $i = 1, \dots, d$ se define como sigue:

$$x_i = \sum_{j=1}^d a_{ij} s_j, \quad (2)$$

donde las s_j son variables latentes continuas que son mutuamente independientes entre si.

- Estas variables latentes se les conoce como **componentes independientes** y siguen una distribución no-Gaussiana.

Análisis de Componentes Independientes (ICA)

- **ICA** representa un **proceso de generación de datos**, donde los componentes independientes s_j se suman con los coeficientes a_{ij} y se observan como x_j .
- En forma matricial, la ecuación (3) se puede representar como:

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (3)$$

- Se puede mostrar que **A** es identificable salvo por el escalamiento y permutaciones sobre las columnas.

Análisis de Componentes Independientes (ICA)

- La matriz de mezcla identificada por los métodos ICA puede escribirse como:

$$\mathbf{A}_{ICA} = \mathbf{A}\mathbf{P}\mathbf{D},$$

donde \mathbf{P} es una matriz de permutación no conocida y \mathbf{D} es matriz diagonal no conocida.

- La mayoría de los métodos de estimación de ICA estiman una matriz conocida como la matriz de separación $\mathbf{W} = \mathbf{A}^{-1}$.

$$\mathbf{W}_{ICA} = \mathbf{PDW} = \mathbf{PDA}^{-1}$$

Resolviendo la ecuación $\mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{e}$ de un LiNGAM para \mathbf{x} se obtiene:

$$\mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{e}$$

$$\mathbf{x} - \mathbf{B}\mathbf{x} = \mathbf{e}$$

$$(\mathbf{I} - \mathbf{B})\mathbf{x} = \mathbf{e}$$

$$\mathbf{x} = (\mathbf{I} - \mathbf{B})^{-1}\mathbf{e}$$

Que se puede escribir como:

$$\mathbf{x} = \mathbf{A}\mathbf{e}, \text{ con } \mathbf{A} = (\mathbf{I} - \mathbf{B})^{-1} \quad (4)$$

Identificación del Modelo utilizando ICA

- Dado que los componentes de \mathbf{e} son independientes y no-Gaussianos, $\mathbf{x} = \mathbf{A}\mathbf{e}$ define un modelo **ICA**, que se sabe que es **identificable**.
- ICA es capaz de estimar \mathbf{A} (y $\mathbf{W} = \mathbf{A}^{-1} = \mathbf{I} - \mathbf{B}$). Sin embargo, exhibe **indeterminaciones de permutación y escalado**.
- ICA regresa $\mathbf{W}_{ICA} = \mathbf{PDW}$, donde \mathbf{P} es una **matriz de permutación desconocida** y \mathbf{D} es una **matriz diagonal desconocida**.

Identificación del Modelo utilizando ICA

- La P correcta es la única que no contiene ceros en la diagonal de DW , dado que B debe ser una matriz que puede permutarse para convertirse una **matriz triangular inferior con ceros en la diagonal** y $W = I - B$.
- Además, la **escala correcta** de los componentes independientes se pueden determinar utilizando los **unos en la diagonal de** $W = I - B$.
- Para obtener W solo es necesario dividir los renglones de DW por sus elementos diagonales correspondientes.
- Finalmente, se puede calcular la **matriz de fuerza de conexión** $B = I - W$.

Algoritmo LiNGAM ICA:

1. Dado un vector aleatorio d -dimensional \mathbf{x} y su matriz $d \times n$ dimensional de datos observados, aplicar un algoritmo ICA para obtener una estimación de \mathbf{A} .
2. Encontrar la permutación única de las filas de $\mathbf{W} = \mathbf{A}^{-1}$ que produce una matriz $\tilde{\mathbf{W}}$ sin ceros en la diagonal principal.
3. Dividir cada fila de $\tilde{\mathbf{W}}$ por su elemento diagonal correspondiente para obtener una nueva matriz $\tilde{\mathbf{W}}'$ con una diagonal que consiste completamente de unos .
4. Calcular una estimación $\hat{\mathbf{B}}$ de \mathbf{B} utilizando $\hat{\mathbf{B}} = \mathbf{I} - \tilde{\mathbf{W}}'$.
5. Finalmente, para estimar un orden causal $k(i)$, determinar la matriz de permutación $\tilde{\mathbf{P}}$ de $\hat{\mathbf{B}}$, obteniendo la matriz $\tilde{\mathbf{B}} = \tilde{\mathbf{P}}\hat{\mathbf{B}}\tilde{\mathbf{P}}^T$ que esté lo más cerca posible a una estructura triangular inferior.