

# Seance 3 pour le groupe Causalité

Sophie Donnet et Zacharie Naulet

March 31, 2025


Vu aux séances 1 et 2.

- Séance 1: paradox de Simpson, potential outcome, counter factual, variables confondantes, hypothèses pour identifier les effets causaux ( $Y(1) - Y(0)$ ) à partir des observations?
- Séance 2: travail sur les DAG ou réseaux bayésiens, lectures d'indépendances conditionnelles à partir de la structure du graphe, d-séparation.

Pour cette séance 3 : do-intervention

## 1 Do-intervention

**Exemple** Considérons 3 variables  $Y$  l'outcome (survie),  $T$  le traitement et  $X$  des covariables qui décrivent le patient. Voici leur DAG



Ainsi les covariables ont une influence à la fois sur la survie et sur le traitement donné au patient. Selon ce DAG, la loi jointe des variables s'écrit:

$$P(Y, T, X) = P(Y | T, X)P(T | X)P(X)$$

La *do*-intervention consiste à remplacer la loi de  $T$  dans la loi jointe ci-dessus par la Dirac  $\delta_{\{T=t\}}$

$$P(Y | T = t, X) \delta_{\{T=t\}} P(X)$$

On note  $Y(t)$  la variable dont la loi est définie par:

$$p_{Y(t)}(y) = \int_x p(y | T = t, X = x) p(x) dx$$

Typiquement on s'intéresse à  $\mathbb{E}[Y(t)]$  : effet causal de  $t$  sur l'outcome

On rencontrera la notation  $Y | do(T = t)$  mais ce n'est pas une loi conditionnelle.

**Définition** Si on a  $\mathbb{X} = X_1, \dots, X_d$  et un DAG.

$$P(x_1, \dots, x_d) = \prod_{i=1}^d P(x_i | pa(x_i))$$

où  $pa(X_i)$  sont les parents des  $X_i$  dans le DAG. Soit  $S$  un sous ensemble de noeuds

$$P(\mathbb{X}_{\bar{S}} | do(S)) = \prod_{i \notin S} P(x_i | pa(x_i))$$

**Do-intervention versus expérience conditionnelle**  $Y(t) \neq Y|T = t$ . En effet,

$$\begin{aligned} p_{Y(t)}(y) &= \int_x p(y | T = t, X = x)p(X = x)dx \\ p_{Y|T=t}(y) &= \int_x p(y | T = t, X = x)p(X = x | T = t)dx \\ &= \int_x p(y | T = t, X = x)\frac{p(T = t, X = x)}{p(T = t)}dx \end{aligned}$$

$p(X = x) = p(X = x | T = t)$  si  $X$  et  $T$  sont indépendantes.

## 2 Modèle causal?


On cherche à comprendre en quoi le sens des flèches est important.

Considérons 3 variables:

- $Y$  la betadiversité d'un écosystème,
- $A$  l'altitude et
- $T$  la température.

On veut comprendre l'effet de  $T$  sur la betadiversité  $Y$ .

**Modèle 1** L'altitude a un effet sur la température ET la biodiversité



On propose le modèle linéaire suivant:

$$\begin{aligned} Y &= \mu_Y + \alpha A + \beta T + \mathcal{N}(0, \sigma_Y^2) \\ T &= \mu_T + \gamma A + \mathcal{N}(0, \sigma_T^2) \\ A &\sim \mathcal{N}(\mu_A, \sigma_A^2) \end{aligned}$$

Dans ce cas, l'effet qui nous intéresse est

$$p(Y(t)) = \int_a p(y|T = t, A = a)p(A = a)da$$

$$Y(t) | T = t, A \sim \mu_Y + \alpha A + \beta t + \mathcal{N}(0, \sigma_Y^2)$$

et


$$A \sim \mathcal{N}(\mu_A, \sigma_A^2)$$

donc

$$\begin{aligned} Y(t) &\sim \mu_Y + \alpha\mu_A + \beta t + \mathcal{N}(0, \alpha^2\sigma_A^2 + \sigma_Y^2) \\ \mathbb{E}[Y(t)] &= \mu_Y + \alpha\mu_A + \beta t \end{aligned}$$

Effet causal de  $T$  sur  $Y$  (causal) =  $\beta$

## Modèle 2



La température a un effet sur l'altitude et la biodiversité. C'est idiot dit comme ça, mais en terme de modèles c'est valable aussi. Les deux modèles sont les mêmes, à reparamétrisation près.

$$\begin{aligned} Y &= \mu_Y + \alpha A + \beta T + \mathcal{N}(0, \sigma_Y^2) \\ A &= \nu_A + \delta T + \mathcal{N}(0, \xi_A^2) \\ T &\sim \mathcal{N}(\nu_T, \xi_T^2) \end{aligned}$$

La deuxième ligne peut être réécrite

$$T = \frac{\nu_A}{\delta} + \frac{1}{\delta}A + \frac{1}{\delta}\mathcal{N}(0, \xi_A^2) = \frac{\nu_A}{\delta} + \frac{1}{\delta}A + \mathcal{N}(0, \frac{\xi_A^2}{\delta^2})$$

et marginalement

$$A \sim \mathcal{N}(\nu_A + \delta\nu_T, \delta^2\xi_T^2 + \xi_A^2)$$

donc les modèles sont les mêmes avec la reparamétrisation suivante:

Model 1	Model 2
$\mu_Y, \alpha, \beta, \sigma_Y^2$	$\mu_Y, \alpha, \beta, \sigma_Y^2$
$\gamma$	$\frac{1}{\delta}$
$\mu_A$	$\nu_A + \delta\nu_T$
$\mu_T$	$\frac{\nu_A}{\delta}$
$\mu_T + \gamma\mu_A$	$\nu_T$
$\sigma_A^2$	$\delta^2\xi_T^2 + \xi_A^2$
$\sigma_T^2$	$\frac{\xi_A^2}{\delta^2}$

$$\gamma := \frac{1}{\delta}$$

Dans ce cas, l'effet qui nous intéresse est

$$p(Y(t)) = \int_a p(y | T = t, A = a)p(A = a | T = t)da$$

$$Y | T = t, A \sim \mu_Y + \alpha A + \beta t + \mathcal{N}(0, \sigma_Y^2)$$

et

$$A | T = t \sim \mathcal{N}(\nu_A + \delta t, \xi_A^2)$$

donc

$$Y(t) \sim \mu_Y + \alpha\nu_A + \alpha\delta t + \beta t + \mathcal{N}(0, \alpha^2\xi_A^2 + \sigma_Y^2)$$

$$\mathbb{E}[Y(t)] = \mu_Y + \alpha\nu_A + (\alpha\delta + \beta)t$$


Effet causal de  $T$  sur  $Y = \beta + \alpha\delta \neq \beta$ . On ajoute l'effet direct ET l'effet indirect.

Ainsi, le DAG (=le sens des flèches) a une influence sur la quantité qui caractérise l'effet dit causal.

## 3 Identifiabilité de l'effet causal

On se demande à quelle condition sur la structure du modèle / réseau bayésien l'effet causal est identifiable à partir de la loi des observations, qui peut seulement porter sur une partie seulement des variables.

**Illustration** Reprenons le modèle linéaire précédent dans sa version 1 .



$$\begin{aligned}
 Y &= \mu_Y + \alpha A + \beta T + \mathcal{N}(0, \sigma_Y^2) \\
 T &= \mu_T + \gamma A + \mathcal{N}(0, \sigma_T^2) \\
 A &\sim \mathcal{N}(\mu_A, \sigma_A^2)
 \end{aligned}$$

$A$  est une variable confondante car elle joue à la fois directement sur  $Y$  mais aussi au travers de  $T$ . On a vu que si on observe l'altitude  $A$ , on peut obtenir l'effet causal  $\beta$  à partir de la loi des observations qui est la loi jointe, en faisant une régression prenant en compte  $A$ . A-t-on accès à cet effet causal  $\beta$  si on n'observe pas  $A$ ?

Supposons que  $A$  soit une variable latente  $\sim \mathcal{N}(\mu_A, \sigma_A^2)$  alors la loi des observations  $(Y, T)$  est encore gaussienne, il faut calculer ses moments;

$$\begin{aligned}
 \mathbb{E}(A) &= \mu_A & \mathbb{E}(T) &= \mu_T + \gamma\mu_A & \mathbb{E}(Y) &= \mu_Y + \alpha\mu_A + \beta\mu_T \\
 \mathbb{V}(A) &= \sigma_A^2 & \mathbb{V}(T) &= \gamma^2\sigma_A^2 + \sigma_T^2 & \text{Cov}(T, A) &= \text{Cov}(\mu_T + \gamma A + \varepsilon_T, A) = \gamma\sigma_A^2
 \end{aligned}$$

En effet

$$\begin{aligned}
 \mathbb{V}(T) &= \mathbb{V}(\mu_T + \gamma A + \varepsilon_T) \\
 &= \gamma^2\mathbb{V}(A) + \sigma_T^2 \\
 &= \gamma^2\sigma_A^2 + \sigma_T^2
 \end{aligned}$$

De plus:

$$\begin{aligned}
 \mathbb{V}(Y) &= \mathbb{V}(\mu_Y + \alpha A + \beta T + \varepsilon_Y) \\
 &= \mathbb{V}(\mu_Y + \alpha A + \beta(\mu_T + \gamma A + \varepsilon_T) + \varepsilon_Y) \\
 &= \mathbb{V}((\alpha + \beta\gamma)A + \beta\varepsilon_T + \varepsilon_Y) \\
 &= (\alpha + \beta\gamma)^2\sigma_A^2 + \beta^2\sigma_T^2 + \sigma_Y^2
 \end{aligned}$$

$$\begin{aligned}
 \text{Cov}(T, Y) &= \text{Cov}(T, Y) \\
 &= \text{Cov}(T, \mu_Y + \alpha A + \beta T + \varepsilon_Y) \\
 &= \alpha\text{Cov}(T, A) + \beta\text{Cov}(T, T) \\
 &= \alpha\text{Cov}(T, A) + \beta(\gamma^2\sigma_A^2 + \sigma_T^2) \\
 &= \alpha\gamma\sigma_A^2 + \beta\gamma^2\sigma_A^2 + \beta\sigma_T^2 \\
 &= \gamma(\alpha + \beta\gamma)\sigma_A^2 + \beta\sigma_T^2
 \end{aligned}$$

$$\begin{pmatrix} Y \\ T \\ A \end{pmatrix} \sim \mathcal{N} \left( \begin{pmatrix} \mu_Y + \alpha\mu_A + \beta\mu_T \\ \mu_T + \gamma\mu_A \\ \mu_A \end{pmatrix}, \begin{pmatrix} (\alpha + \beta\gamma)^2\sigma_A^2 + \beta^2\sigma_T^2 + \sigma_Y^2 & & \\ \gamma(\alpha + \beta\gamma)\sigma_A^2 + \beta\sigma_T^2 & \gamma^2\sigma_A^2 + \sigma_T^2 & \\ & \gamma\sigma_A^2 & \sigma_A^2 \end{pmatrix} \right)$$

Ainsi, la loi marginale de  $(Y, T)$  est:

$$\begin{pmatrix} Y \\ T \end{pmatrix} \sim \mathcal{N} \left( \begin{pmatrix} \mu_Y + \alpha\mu_A + \beta\mu_T \\ \mu_T + \gamma\mu_A \end{pmatrix}, \begin{pmatrix} (\alpha + \beta\gamma)^2\sigma_A^2 + \beta^2\sigma_T^2 + \sigma_Y^2 & \\ \gamma(\alpha + \beta\gamma)\sigma_A^2 + \beta\sigma_T^2 & \gamma^2\sigma_A^2 + \sigma_T^2 \end{pmatrix} \right)$$

On voit difficilement comment identifier le paramètre  $\beta$  à partir de cette loi marginale. Ie. exprimer  $\beta$  en fonction des moments de cette loi? On peut creuser et exprimer la loi conditionnelle de  $Y|T$

*Rappel* Si  $(Z_1, Z_2) \sim \mathcal{N}((\mu_1, \mu_2), \Sigma)$  alors  $Z_1|Z_2 = z$  est aussi gaussienne de moyenne

$$m(z_2) = \mu_1 - \frac{\Sigma_{12}}{\Sigma_{22}}(z_2 - \mu_2)$$

et de variance

$$\bar{\Sigma} = \Sigma_{11} - \frac{\Sigma_{12}^2}{\Sigma_{22}}$$

Donc ici : une fois les  $A$  intégrés,  $Y|T$  suit la loi:

$$\begin{aligned} Y &= \mu_Y + \alpha\mu_A + \beta\mu_T - \frac{\gamma(\alpha + \beta\gamma)\sigma_A^2 + \beta\sigma_T^2}{\gamma^2\sigma_A^2 + \sigma_T^2}(T - \mu_T + \gamma\mu_A) + \tilde{\varepsilon} \\ &= \tilde{\mu}_Y + \frac{\gamma(\alpha + \beta\gamma)\sigma_A^2 + \beta\sigma_T^2}{\gamma^2\sigma_A^2 + \sigma_T^2}T + \tilde{\varepsilon} \\ &= \tilde{\mu}_Y + \left( \beta + \frac{\gamma\alpha\sigma_A^2}{\gamma^2\sigma_A^2 + \sigma_T^2} \right)T + \tilde{\varepsilon} \end{aligned}$$

Ainsi, si je fais une regression de  $Y$  contre  $T$  sans corriger par  $A$ , je vais estimer non pas  $\beta$  tout seul mais  $\beta + \frac{\gamma\alpha}{\gamma^2\sigma_A^2 + \sigma_T^2}$  donc je vais avoir un biais dans mon estimation.

*Remarque qui rassure* : si  $\gamma = 0$  (pas d'effet de l'altitude sur la température),  $\alpha = 0$  (par d'effet de l'altitude sur  $Y$ ) ou  $\sigma_A^2 = 0$  ( $A$  non aléatoire) , l'estimateur est sans biais.

**Question** Dans un modèle plus complexe contenant  $d$  variables  $(X_1, \dots, X_d)$  dont j'ai le DAG. Je veux identifier l'effet causal de  $X_1$  sur  $X_d$  (au sens vu ci dessus). Supposons que je n'observe pas toutes les variables mais seulement un sous-ensemble de ces variables :  $W \subset \{X_2, \dots, X_{d-1}\}$

Cet ensemble  $W$  est-t-il suffisant pour identifier l'effet causal de  $X_1$  sur  $X_d$ ? au sens où est-ce que j'arrive à écrire la loi de  $X_d(x_1)$  à partir de la loi observationnelle  $P(X_1, X_d, W)$ ?

## 4 Backdoor criterion

Establishes a sufficient condition for nonparametric identifiability of causal effects.

Recall from last session: path, blocked path.

Here we introduce backdoor path:

**Definition 1** (backdoor path). *A backdoor path from  $X_k$  to  $X_\ell$  is a path  $(X_{i_1}, \dots, X_{i_n})$  with  $i_1 = k$ ,  $i_n = \ell$ , and an ingoing edge  $X_{i_1} \leftarrow X_{i_2}$  (ie. the path "enters"  $X_k$  through the backdoor).*

Example:

- $A \leftarrow B \rightarrow C$  is a backdoor path from  $A$  to  $C$  :
- $A \rightarrow B \rightarrow C$  is not a backdoor path.

Without loss of generality we consider random variables  $(X_1, \dots, X_d)$  and we wish to identify the causal effect of  $X_1$  on  $X_d$ ; ie establish that the "post-intervention" distribution of  $X_d$  can be written as a function of the "observational" distribution  $P$ .

First remark that if  $P$  is the joint distribution of  $(X_1, \dots, X_d)$  – ie. everything is observed – then we know all the conditional distributions of  $P$  and the causal effect is trivially identifiable.

Here we are interested in finding a subset  $W \subset \{X_2, \dots, X_{d-1}\}$  of variables for which the "post-intervention" distribution of  $X_d$  can be written as a function of the "observational" marginal distribution of  $\{X_1, X_2\} \cup W$ .

**Definition 2** (Backdoor criterion). *A set of variables  $W \subset \{X_2, \dots, X_{d-1}\}$  satisfies the backdoor criterion relative to  $(X_1, X_d)$  if:*

- $W$  blocks all backdoor paths from  $X_1$  to  $X_d$  ;
- $W$  contains no descendent of  $X_1$ .

**Theorem 1.** *If  $W$  satisfies the backdoor criterion, then the causal effect of  $X_1$  on  $X_d$  is identifiable from the observational distribution of  $\{X_1, X_d\} \cup W$ .*

*Proof.* Let  $P$  be the observational distribution of  $(X_1, \dots, X_d)$ . By assumption  $P$  is Markov with respect to the DAG  $G$ . We write  $\text{pa}_i$  the set of indices of parents of  $X_i$ .

We assume that  $P$  admits conditional distributions of  $X_i$  given  $(X_j)_{j \in \text{pa}_i}$  that have densities wrt some measures given by  $\mu_i(\cdot | (x_j)_{j \in \text{pa}_i})$ ; so  $p$  has the density

$$p_{1:d}(x_1, \dots, x_d) = \prod_{i=1}^d \mu_i(x_i | (x_j)_{j \in \text{pa}_i}).$$

We are interested in the intervention  $\text{do}(X_1 = x)$ , which leads to the "post-interventional" density:

$$p_{1:d}^{\text{do}}(x_1, \dots, x_d) = \mathbf{1}_{\{x_1=x\}} \prod_{i=2}^d \mu_i(x_i | (x_j)_{j \in \text{pa}_i}).$$

In particular we wish to show that the marginal  $p_{1:d}^{\text{do}}$  on  $X_d$  can be written as a function of the marginal of  $p_{1:d}$  on  $\{X_1, X_d\} \cup W$ .

The main trick is the following. We introduce a new random variable  $X_0 \in \{0, 1\}$  and a joint distribution  $P'$  for  $(X_0, \dots, X_d)$  such that  $P'$  has the density

$$p'_{0:d}(x_0, \dots, x_d) = p'_0(x_0) \mu'_1(x_1 | (x_j)_{j \in \text{pa}_1}, x_0) \prod_{i=2}^d \mu_i(x_i | (x_j)_{j \in \text{pa}_i})$$

where

$$\mu'_1(x_1 | (x_j)_{j \in \text{pa}_1}, x_0) = \begin{cases} \mu_1(x_1 | (x_j)_{j \in \text{pa}_1}) & \text{if } x_0 = 0, \\ \mathbf{1}_{\{x_1=x\}} & \text{if } x_0 = 1. \end{cases}$$

Observe that  $P'$  is Markov with respect to the graph  $G'$  obtained from  $G$  by adding a vertex  $X_0$  and a directed edge  $X_0 \rightarrow X_1$ . Furthermore,

$$\begin{aligned} P'(X_1 \in \cdot, \dots, X_d \in \cdot | X_0 = 0) &= P \\ P'(X_1 \in \cdot, \dots, X_d \in \cdot | X_0 = 1) &= P^{\text{do}}. \end{aligned}$$

Now using "obvious" notations:

$$\begin{aligned} p_d^{\text{do}}(x_d) &= p'_{d|0}(x_d | X_0 = 1) \\ &= \int p'_{d|0,W}(x_d | X_0 = 1, W = w) p'_{W|0}(dw | X_0 = 1) \end{aligned}$$

Remark that under  $P'$ , conditional to  $X_0 = 1$  it is the case that  $X_1 = x$   $P'$ -almost-surely. Therefore the previous indeed equals

$$p_d^{\text{do}}(x_d) = \int p'_{d|0:1,W}(x_d | X_0 = 1, X_1 = x, W = w) p'_{W|0}(dw | X_0 = 1).$$

Now we make the following two observations. Under  $P'$ :

- Conditional to  $(W, X_1)$  the variables  $X_0$  and  $X_d$  are independent. This is because in  $G'$ , all the paths from  $X_0$  to  $X_d$  must
  - either go through one of the backdoor path from  $X_1$  to  $X_d$ , which is by assumption blocked by  $W$  ;

- either go through  $X_0 \rightarrow X_1 \rightarrow$  some child of  $X_1$ , which is a chain where the middle node is conditioned on  $\implies$  blocked by  $X_1$ .

It follows that

$$\begin{aligned} p'_{d|0:1,W}(x_d | X_0 = 1, X_1 = x, W = w) &= p'_{d|1,W}(x_d | X_1 = x, W = w) \\ &= p'_{d|0:1,W}(x_d | X_0 = 0, X_1 = x, W = w) \\ &= p_{d|1,W}(x_d | X_1 = x, W = w). \end{aligned}$$

- $W$  and  $X_0$  are independent. By assumption, no vertex of  $W$  is a descendent of  $X_1$ . This implies that all paths from  $X_0$  to  $W$  contains a collider [draw picture!]. Hence

$$\begin{aligned} p'_{W|0}(w | X_0 = 1) &= p'_W(w) \\ &= p'_{W|0}(w | X_0 = 0) \\ &= p_W(w). \end{aligned}$$


Gathering these two remarks:

$$p_d^{\text{do}}(x_d) = \int p_{d|1,W}(x_d | X_1 = x, W = w) p_W(dw).$$

Note that the rhs of the last display is solely a function of the marginal of  $P$  on  $(X_1, X_d, W)$ . □

## 4.1 Applications

### 4.1.1 Application 1 : modèle $(Y, T, A)$



Effet causal de  $T$  sur  $Y$ .  
Backdoor paths

- $T \leftarrow A \rightarrow Y$  : open


Si on choisit  $W = \emptyset$ , il existe un open backdoor ne passant pas par  $W$ . Le critère ne s'applique pas (mais il n'est pas suffisant:!).

### 4.1.2 Application 2 : modèle plus complexe

From site [mixtape](#)

- $Y$  = earning
- $D$  = level of education
- $I$  = family income
- $PE$  = parental education
- $B$  = background : genetics, environment

On veut identifier l'effet causal de  $D$  sur  $Y$ .



Effet causal de  $D \rightarrow Y$

Backdoor paths

- $D \leftarrow I \rightarrow Y$
- $D \leftarrow PE \rightarrow I \rightarrow Y$
- $D \leftarrow B \rightarrow PE \rightarrow I \rightarrow Y$

Si on pose  $W = \{I\}$  : tous les open Backdoor paths passent pas  $W$ . Donc il suffit de prendre  $I$  en compte avoir une estimation "sans biais" de l'effet causal...

## References

- [Cam20] John Campbell. *Causation in Psychology*. Harvard University Press, 2020.
- [GCL<sup>+</sup>21] Ruocheng Guo, Lu Cheng, Jundong Li, P. Richard Hahn, and Huan Liu. A Survey of Learning Causality with Data: Problems and Methods. *ACM Computing Surveys*, 53(4):1–37, July 2021. arXiv:1809.09337 [cs].
- [GZS19] Clark Glymour, Kun Zhang, and Peter Spirtes. Review of Causal Discovery Methods Based on Graphical Models. *Frontiers in Genetics*, 10:524, June 2019.
- [HHG24] Uzma Hasan, Emam Hossain, and Md Osman Gani. A Survey on Causal Discovery Methods for I.I.D. and Time Series Data, March 2024. arXiv:2303.15027 [cs].
- [IR15] Guido W. Imbens and Donald B. Rubin. *Causal Inference for Statistics, Social, and Biomedical Sciences: An Introduction*. Cambridge University Press, 2015.
- [MSK<sup>+</sup>21] Raha Moraffah, Paras Sheth, Mansooreh Karami, Anchit Bhattacharya, Qianru Wang, Anique Tahir, Adrienne Raglin, and Huan Liu. Causal Inference for Time series Analysis: Problems, Methods and Evaluation, February 2021. arXiv:2102.05829 [cs].
- [Nea] Brady Neal. Introduction to Causal Inference.
- [NPR<sup>+</sup>22] Ana Rita Nogueira, Andrea Pugnana, Salvatore Ruggieri, Dino Pedreschi, and João Gama. Methods and tools for causal discovery and causal inference. *WIREs Data Mining and Knowledge Discovery*, 12(2):e1449, March 2022.
- [Pea00] Judea Pearl. *Causality*. Cambridge University Press, New York, 2000.
- [Sha18] Ramalingam Shanmugam. Elements of causal inference: foundations and learning algorithms. *Journal of Statistical Computation and Simulation*, 88(16):3248–3248, November 2018.
- [SJH<sup>+</sup>] Shohei Shimizu, Ism Ac Jp, Patrik O Hoyer, Patrik Hoyer, Aapo Hyvarinen, Aapo Hyvarinen, Antti Kerminen, and Antti Kerminen. A Linear Non-Gaussian Acyclic Model for Causal Discovery.
- [Wag] Stefan Wager. STATS 361: Causal Inference.
- [Zha] Qingyuan Zhao. Lecture Notes on Causal Inference.
- [ZS23] Alessio Zanga and Fabio Stella. A Survey on Causal Discovery: Theory and Practice, May 2023. arXiv:2305.10032 [cs].