

## Modélisation et identification causale

### Séance 4 – Pourquoi contrôler les caractéristiques observables ?

Pierre Pora

2022-12-01

## “Il faudrait contrôler de etc.”

- ▶ **Cette semaine :**

- ▶ Qu'est-ce que cela signifie exactement ?
- ▶ Pourquoi faut-il le faire ?
- ▶ Comment sait-on de quoi il faut contrôler ?

- ▶ **La semaine prochaine**

- ▶ Comment fait-on au juste pour contrôler ?

- ▶ **Deux questions très différentes**

- ▶ La première se passe en fait totalement de données !
- ▶ La seconde y fait lourdement appel

Manipuler quelques concepts de causalité

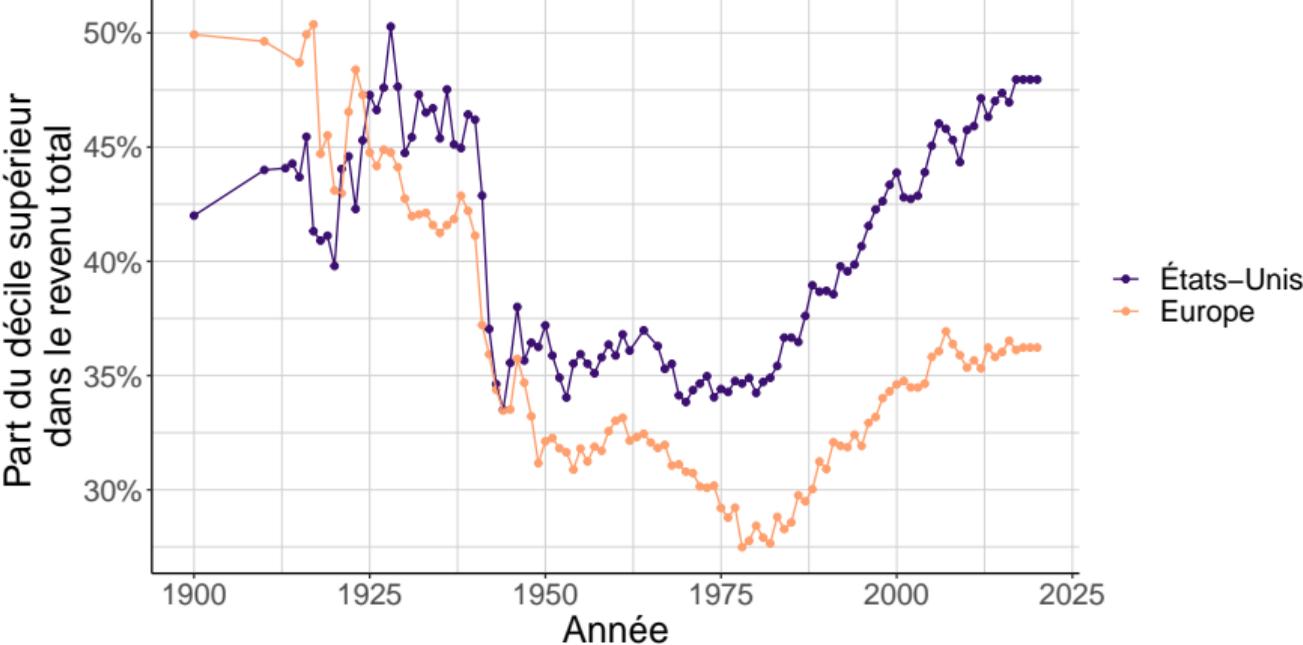
La France comptait 67 millions d'habitants en 2018

- ▶ Est-ce une **proposition causale** ?

La France comptait 67 millions d'habitants en 2018

- ▶ Est-ce une **proposition causale** ?
- ▶ Non : **une proposition causale est une comparaison**

La comparaison faite dans ce graphique (Piketty (2019)) est-elle une proposition causale ?



La comparaison faite dans ce graphique est-elle une proposition causale ?

- ▶ Non : **une proposition causale compare des situations dont au moins une est hypothétique / contrefactuelle**

## Une tentative de définition

Une **proposition causale** est une proposition qui **compare** la situation d'**entités homologues** entre plusieurs **mondes possibles** différents résultant d'une certaine **variation contrefactuelle**. Sa forme typique est : *si le monde différait du monde observé de telle ou telle façon, alors tel aspect s'en trouverait également changé.*

## Problème fondamental de l'inférence causale (Holland (1986))

- ▶ **Le monde hypothétique que l'on cherche à comparer au monde observé n'est *jamais* observé**
- ▶ Les effets causaux **ne peuvent pas** être des résultats simples de la collecte de données sur le monde observé
  - ▶ Collecter davantage de données, ou de meilleures données n'y changera rien

## Modèle causal de Neyman-Rubin (Splawa-Neyman, Dabrowska, and Speed (1990); Rubin (1974)) : la population

- ▶ Modèle issu de la **statistique agricole**, arrivé en sciences sociales en particulier par analogie avec les **sciences médicales**
- ▶ On a une **population d'individus** qu'on peut indexer par  $i$  allant de 1 à  $N$ 
  - ▶ Pour la statistique agricole : des parcelles
  - ▶ Pour les sciences médicales : des patients
  - ▶ Pour les sciences sociales : ce qu'on veut selon le problème que l'on traite → des êtres humains, des zones géographiques, des objets, des organisations. . .

## Modèle causal de Neyman-Rubin (Splawa-Neyman, Dabrowska, and Speed (1990); Rubin (1974)) : l'intervention

- ▶ **Conception interventionniste de la causalité** : on veut connaître les effets d'une intervention, c'est-à-dire d'une manipulation possible du monde
- ▶ Cas simple, potentiellement généralisable : **l'intervention a deux valeurs possibles**
  - ▶  $d = 0$  ne pas faire l'objet de l'intervention
  - ▶  $d = 1$  faire l'objet de l'intervention
- ▶ En statistique agricole : semer une variété plutôt qu'une autre ; en sciences médicales : utiliser un traitement plutôt qu'un autre ; en sciences sociales : à définir selon les besoins.
- ▶ **Cas généralisable** à des interventions plus compliquées !

## Modèle causal de Neyman-Rubin (Splawa-Neyman, Dabrowska, and Speed (1990); Rubin (1974)) : variable d'intérêt

- ▶ On s'intéresse à une certaine **variable d'intérêt**  $Y$  qui doit quantifier les effets de l'intervention
  - ▶ en statistique agricole : les rendements agricoles
  - ▶ en sciences médicales : la survie des patients, leur guérison
  - ▶ en sciences sociales : ce dont on a besoin
- ▶ Pour chaque individu de la population on peut donner un sens aux **valeurs potentielles** de la variable :
  - ▶  $Y_i(0)$  la valeur si  $i$  ne faisait pas l'objet de l'intervention
  - ▶  $Y_i(1)$  la valeur si  $i$  faisait l'objet de l'intervention

## Modèle causal de Neyman-Rubin (Splawa-Neyman, Dabrowska, and Speed (1990); Rubin (1974)) : effet causal

- ▶ L'**effet causal** de l'intervention sur l'individu  $i$  :  $Y_i(1) - Y_i(0)$ 
  - ▶ Peut varier d'un individu à l'autre → **effets causaux hétérogènes**
  - ▶ Tout le monde ne réagit pas pareil à l'intervention
  - ▶ **Formalisme additif** facile à utiliser et d'une grande généralité
    - ▶ On peut faire des choix plus compliqués si nécessaire

## Modèle causal de Neyman-Rubin (Splawa-Neyman, Dabrowska, and Speed (1990); Rubin (1974)) : des valeurs potentielles aux valeurs observées

- ▶ On n'observe que :
  - ▶  $Y_i = Y_i(0)$  si  $i$  ne fait pas l'objet de l'intervention
  - ▶  $Y_i = Y_i(1)$  si  $i$  fait l'objet de l'intervention
- ▶ ***Les effets causaux individuels ne peuvent jamais être observés*** (problème fondamental de l'inférence causale, cf supra)

## Une solution au problème fondamental de l'inférence causale

- ▶ On ne peut jamais rien dire sur les effets causaux individuels qui soit empiriquement testable
- ▶ Mais on peut parfois dire des choses sur les **effets causaux moyens**
- ▶ C'est une solution statistique au problème

## Rappel de probabilités : notion d'espérance et d'espérance conditionnelle

- ▶ Schématiquement : **espérance** ( $\mathbb{E}[Y]$ ) = moyenne dans la population vs. **moyenne empirique** = moyenne dans l'échantillon
- ▶ **Loi des grands nombres** : quand l'échantillon est assez grand la seconde tend vers la première
- ▶ **Espérance conditionnelle** ( $\mathbb{E}[Y | X = x]$ ) : moyenne dans la population pour un groupe défini par la valeur d'une certaine variable
  - ▶ dans la strate définie par  $X = x$

## Notions d'effets causaux moyens

- ▶ Effets causaux moyens **sur toute la population** (ATE)  $\mathbb{E}[Y_i(1) - Y_i(0)]$
- ▶ Effets causaux moyens **sur ceux qui ont fait l'objet de l'intervention** (ATT)  $\mathbb{E}[Y_i(1) - Y_i(0) \mid D_i = 1]$
- ▶ Effets causaux moyens **sur ceux qui n'ont pas fait l'objet de l'intervention** (ATU)  $\mathbb{E}[Y_i(1) - Y_i(0) \mid D_i = 0]$

## Comment identifier les effets d'une intervention dans une expérience aléatoire contrôlée ?

- ▶ Supposez que vous disposez de données issues d'une **expérience aléatoire contrôlée**, telles que pour chaque individu vous connaissez son statut vis-à-vis de l'intervention (a-t-il fait l'objet de l'intervention ou non) et la variable d'intérêt
- ▶ Pouvez-vous **identifier les effets causaux moyens** de l'intervention ?
- ▶ De quelle façon ?

## Comment identifier les effets d'une intervention dans une expérience naturelle ?

- ▶ Supposez que vous disposez de données issues d'une **expérience naturelle**, telles que pour chaque individu vous connaissez son statut vis-à-vis de l'intervention (a-t-il fait l'objet de l'intervention ou non) et la variable d'intérêt
- ▶ Pouvez-vous **identifier les effets causaux moyens** de l'intervention ?
- ▶ De quelle façon ?

## Interprétation causale des comparaisons simples

- ▶ Elle n'est garantie que pour les **expériences aléatoires contrôlées** et les **expériences naturelles**
- ▶ Interpréter de façon causale la différence moyenne entre les individus qui ont fait l'objet d'une intervention et les autres, c'est dire que **la situation que l'on étudie peut s'assimiler à une expérience aléatoire contrôlée** ou à une expérience naturelle (*as good as random*)

## Remarque : hypothèses implicites du modèle de Neyman-Rubin

- ▶ **Stabilité des individus entre les mondes contrefactuels** : il faut que considérer le même individu  $i$  dans les deux situations hypothétiques ait un sens, et que la valeur  $Y_i(d)$  ait un sens dans les deux cas
  - ▶ OK pour la statistique agricole et les sciences médicales
  - ▶ En sciences sociales il faut parfois faire attention ! → e.g. salaire des chômeurs, résultat des entreprises non-crées etc.
- ▶ Il faut que **ce qui arrive à  $i$  ne dépende pas de ce qui arrive à  $j \neq i$** 
  - ▶ ~ OK en statistique agricole si les parcelles ne sont pas trop proches
  - ▶ Pas toujours évident en sciences médicales ou sociales
- ▶ Il y a des techniques pour gérer les deux problèmes → sujet plus avancé, un peu abordé dans le support écrit

Pour commencer avec le contrôle des facteurs confondants : les admissions à Berkeley sont-elles biaisées selon le genre ?

## Un exercice empirique

- ▶ Les données stockées dans `UBCadmissions`, accessibles par le package `datasets` représentent de façon agrégée les décisions d'admission en *graduate school* à Berkeley en 1973 (Bickel, Hammel, and O'Connell (1975))
- ▶ Quel est l'**écart de taux d'admission entre hommes et femmes** ? Cet écart a-t-il une interprétation causale ?
- ▶ Quel est le département pour lequel l'écart est le plus grand ? Combien vaut l'écart de taux d'admission pour ce département ?
- ▶ Que faut-il en conclure ?

## Les femmes sont bien moins souvent admises que les hommes

```
library(datasets)
library(data.table)

sexbias_dat<-data.table(UCBAdmissions)

#On compare la part d'admis parmi les candidats selon le sexe
sexbias_dat[,
  list(part=sum(as.numeric(Admit=="Admitted")*
               N)/
        sum(N)*
        100),
  by="Gender"]
```

```
##      Gender      part
## 1:   Male 44.51877
## 2: Female 30.35422
```

## Les choses sont très différentes si l'on regarde département par département

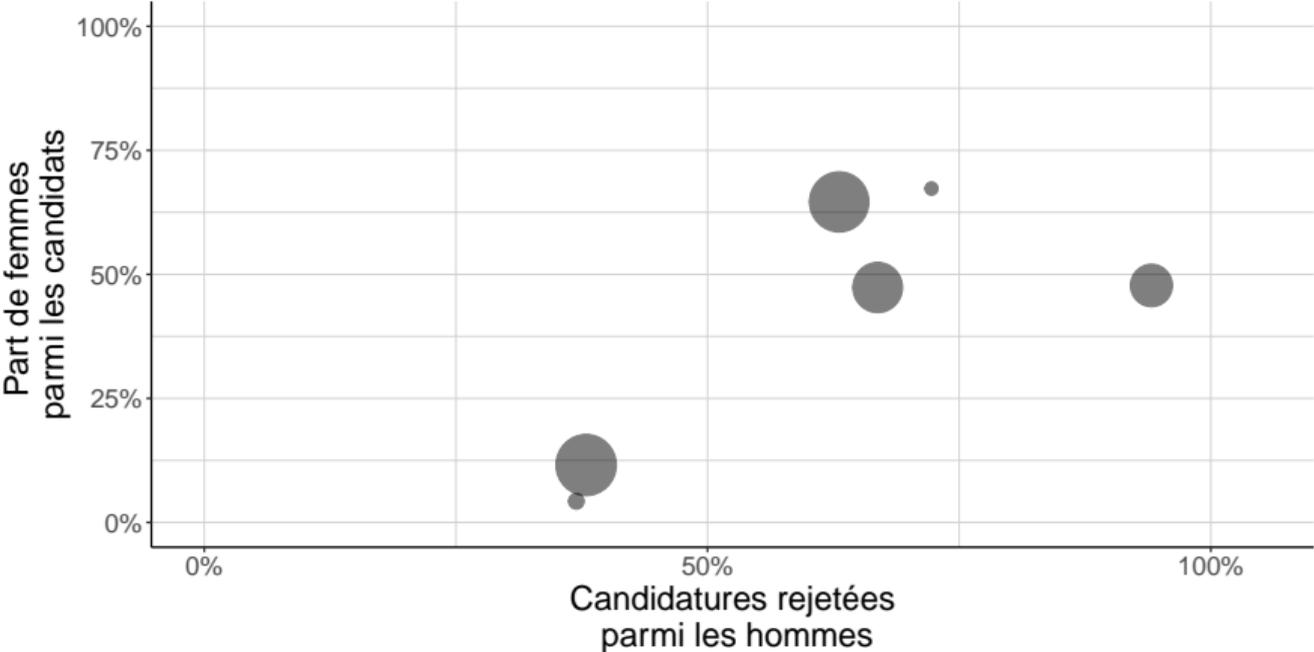
```
#On compare la part d'admis parmi les candidats selon le sexe pour chaque  
# département  
sexbias_dat_par_dept<-  
  sexbias_dat[,  
    list(ecart_taux_admission=  
          (sum(as.numeric(Admit=="Admitted")*  
              as.numeric(Gender=="Female")*  
              N)/  
          sum(as.numeric(Gender=="Female")*N)-  
          sum(as.numeric(Admit=="Admitted")*  
              as.numeric(Gender=="Male")*  
              N)/  
          sum(as.numeric(Gender=="Male")*N))*  
          100),  
    by="Dept"]
```

## Les choses sont très différentes si l'on regarde département par département

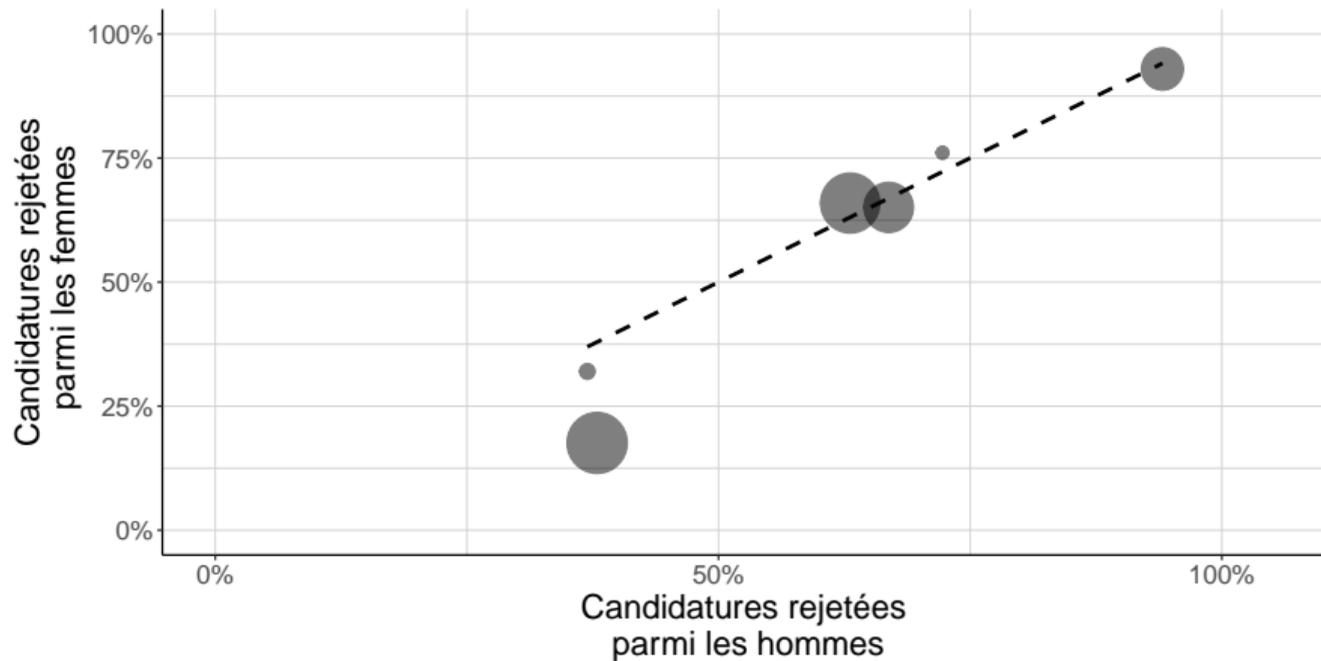
```
#On compare la part d'admis parmi les candidats selon le sexe pour chaque  
# département  
sexbias_dat_par_dept
```

```
##      Dept ecart_taux_admission  
## 1:      A          20.346801  
## 2:      B           4.964286  
## 3:      C          -2.858996  
## 4:      D           1.839808  
## 5:      E          -3.830116  
## 6:      F           1.140000
```

# Les femmes sont plus nombreuses à candidater aux départements les plus sélectifs



La sélectivité de chaque département n'est pas très différente pour les femmes et pour les hommes, ou bien en faveur des femmes



## Que faut-il en tirer ?

- ▶ Les résultats sont **très différents** selon que l'on fait la comparaison sur UC Berkeley dans son ensemble ou département par département
- ▶ Pour faire une interprétation causale de ces comparaisons, il faut imaginer deux expériences aléatoires contrôlées différentes l'une de l'autre
  - ▶ avant que la candidature parvienne à l'université, on manipule aléatoirement le dossier pour qu'il semble provenir d'un homme ou d'une femme, **avec une probabilité qui est la même pour toutes les candidatures soumises à l'université**
  - ▶ avant que la candidature parvienne à l'université, on manipule aléatoirement le dossier pour qu'il semble provenir d'un homme ou d'une femme, **avec une probabilité qui est la même pour toutes les candidatures soumises à un département, mais qui varie d'un département à l'autre de l'université**
- ▶ Parce que la part de candidatures adressées par des femmes varie beaucoup d'un département à l'autre, **seule la deuxième solution est compatible avec les données collectées**

## Que faut-il en tirer ?

- ▶ L'interprétation causale de ces comparaisons fait donc l'**hypothèse que chaque département fait séparément sa propre expérience aléatoire contrôlée**
- ▶ Peut-on **identifier les effets causaux moyens du sexe** sur l'admission dans ces conditions ?
  - ▶ Utiliser les données pour estimer le **taux contrefactuel d'admission pour les femmes** si leurs dossiers étaient perçus comme des dossiers envoyés par des hommes
  - ▶ Utiliser les données pour estimer les **effets causaux moyens du sexe sur l'admission**

## Identifier les effets causaux moyens du sexe sur l'admission

- ▶ Pour estimer les effets causaux moyens du sexe sur l'admission, on fait des **comparaisons à l'intérieur de chaque département** :
  - ▶ on dit que l'on **conditionne sur la variable de département**
  - ▶ c'est-à-dire qu'on compare entre eux seulement des dossiers adressés au même département
  - ▶ ce que l'on fait en considérant les taux d'admission dans des strates définis par les valeurs de la variable de département ( $\sim$  espérance conditionnelle)
- ▶ Puis on peut **réagrèger** tout ça au niveau de UC Berkeley prise en entier (avec des poids bien choisis)

## Les deux hypothèses clés

- ▶ **Hypothèse d'indépendance conditionnelle** : à l'intérieur de chaque département, tout se passe comme si on était devant une expérience aléatoire contrôlée ou une expérience naturelle
  - ▶ Le sexe est indépendant des valeurs potentielles de la décision d'admission, conditionnellement au département
- ▶ **Hypothèse de support commun** : la part de dossiers envoyés par des femmes dans chaque département est différente de 0 et 100%
  - ▶ sinon on ne peut plus définir la différence entre femmes et hommes dans le département !

## Estimer le taux contrefactuel d'admission pour les femmes si leurs dossiers étaient perçu comme des dossiers envoyés par des hommes

```
#Il faut simplement sommer les taux d'admission des hommes dans les  
# différents départements, avec des poids proportionnels au nombre de  
# candidatures adressées à chaque département par des femmes.
```

```
taux_contrefactuel<-100*(  
  1-  
    sexbias_dat_dpt[,  
      list(taux_contrefactuel=  
        sum(selectivite_hommes*  
          part_femmes*  
          taille)/  
        sum(part_femmes*  
          taille))])  
taux_contrefactuel
```

```
##      taux_contrefactuel  
## 1:          30.24544
```

## Estimer les effets causaux moyens du sexe sur l'admission : ATE

```
#Pour l'effet causal moyen sur toute la population, il faut faire la moyenne  
# des différences entre les taux d'admission des femmes et des hommes dans  
# chaque département avec des poids proportionnels au nombre total de  
# candidatures reçues
```

```
ATE<-sexbias_dat_dpt[,  
  list(ATE=sum(100*(  
    (1-selectivite_femmes)-  
    (1-selectivite_hommes))*  
    taille)/  
    sum(taille))]
```

```
ATE
```

```
##          ATE  
## 1: 4.26368
```

## Estimer les effets causaux moyens du sexe sur l'admission : ATT

*#Pour l'effet causal moyen chez les femmes, il faut utiliser des poids  
# proportionnels au nombre de candidatures féminines reçues par chaque  
# département*

```
ATT<-sexbias_dat_dpt[,  
    list(ATT=sum(100*(  
        (1-selectivite_femmes)-  
        (1-selectivite_hommes))*  
        taille*  
        part_femmes)/  
        sum(taille*  
            part_femmes)))]
```

ATT

```
##          ATT  
## 1: 0.108779
```

## Estimer les effets causaux moyens du sexe sur l'admission : ATU

*#Pour l'effet causal moyen chez les hommes, il faut utiliser des poids  
# proportionnels au nombre de candidatures masculines reçues par chaque  
# département*

```
ATU<-sexbias_dat_dpt[,  
  list(ATU=sum(100*(  
    (1-selectivite_femmes)-  
    (1-selectivite_hommes))*  
    taille*  
    (1-part_femmes))/  
    sum(taille*  
      (1-part_femmes))))]
```

ATU

```
##          ATU  
## 1: 7.096918
```

## Estimer les effets causaux moyens : une petite question

- ▶ Si on connaît l'**ATT** et l'**ATU**, sait-on en déduire l'**ATE** ?

## Estimer les effets causaux moyens : une petite question

```
#On peut vérifier que l'ATE est bien égal à la moyenne pondérée de l'ATT  
# et de l'ATU avec des poids égaux aux parts respectives des deux  
# sous-populations dans l'ensemble des candidatures  
effectifs_sexe<-sexbias_dat[,  
                                list(effectif=sum(N)),  
                                by="Gender"]  
ATE_calcul_alternatif<-  
  (effectifs_sexe[Gender=="Male"]$effectif*ATU$ATU+  
    effectifs_sexe[Gender=="Female"]$effectif*ATT$ATT)/  
  (sum(effectifs_sexe$effectif))  
all.equal(as.numeric(ATE),  
          ATE_calcul_alternatif)  
  
## [1] TRUE
```

Appuyer graphiquement l'hypothèse d'indépendance  
conditionnelle

## Peut-on croire à l'hypothèse d'indépendance conditionnelle ?

- ▶ L'hypothèse d'indépendance conditionnelle assure que l'on peut identifier les effets causaux en raisonnant à l'intérieur de sous-populations
  - ▶ ou ce qui revient au même à **l'intérieur de strates définies par la valeur de certaines variables**
- ▶ Si on sait que c'est vrai parce que l'on a fait une **expérience aléatoire stratifiée**, c'est-à-dire une expérience aléatoire contrôlée dans chacune de ces strates, ou que l'on sait qu'on regarde une expérience naturelle quand on raisonne à l'intérieur d'une strate, alors on a gagné
- ▶ Mais **c'est rarement le cas** ! Comment faire alors ?
- ▶ En particulier la crédibilité de l'hypothèse d'indépendance conditionnelle dépend de la définition des strates, c'est-à-dire encore du choix des variables sur lesquelles on conditionne → **comment choisir ?**

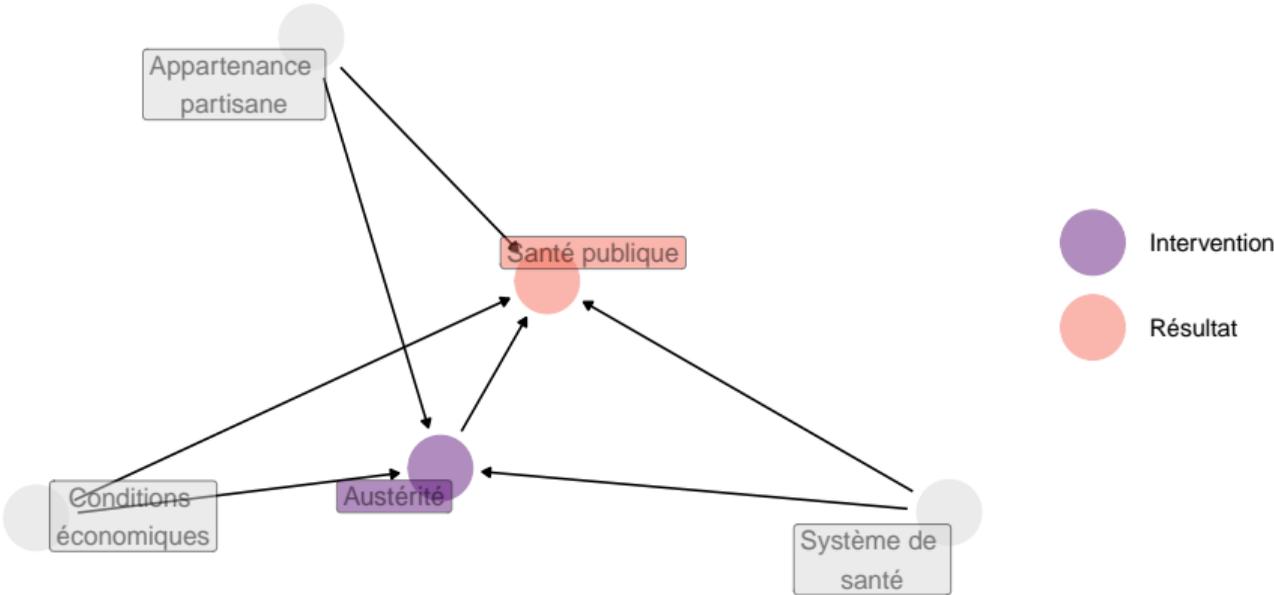
## Approches graphiques de la causalité

- ▶ Approches qui ont une histoire longue mais dont les **développements récents doivent beaucoup à Judea Pearl (informaticien)**
- ▶ Permet de **dépasser les discussions un peu heuristiques et les arguments un peu relâchés** sur le choix des variables de conditionnement et la crédibilité de l'hypothèse d'indépendance conditionnelle

# Approches graphiques de la causalité

- ▶ **Approche quantitative mais pas fondée sur les données**
- ▶ L'idée :
  - ▶ **représenter graphiquement** la question que l'on se pose
  - ▶ cette représentation graphique est l'objet d'un **traitement informatique** qui indique
    - ▶ **s'il existe (au moins) un ensemble des variables de conditionnement** tel que l'hypothèse d'indépendance conditionnelle est crédible
    - ▶ **quelles variables** appartiennent à cet ensemble (ces ensembles)
- ▶ **Package** `ggdag` disponible pour R

# Représentation graphique de la causalité : un exemple (Jacques and Noël (2022))



## Les ingrédients de la représentation graphique

- ▶ Des **nœuds** qui correspondent aux différentes variables du problème
- ▶ Des **flèches** qui représentent le flot de causalité d'une variable à l'autre
- ▶ Une variable est la **variable d'intervention**
- ▶ Une variable est le **résultat** ou la **variable d'intérêt**

## Coder l'objet qui génère la représentation graphique dans ggdag

```
graph_jacques<-dagify(SantePub~Austerite+AppartParti+SystemeSante+ConditEco,  
  #Pour chaque nœud auquel aboutit au moins une flèche,  
  # on recense d'où partent toutes ces flèches  
  Austerite~AppartParti+SystemeSante+ConditEco,  
  exposure = "Austerite",  
  #La variable qui correspond à l'intervention dont on  
  # souhaite étudier les effets  
  outcome = "SantePub",  
  #La variable qui correspond aux conséquences que l'on  
  # voudrait pouvoir mesurer  
  labels = c("SantePub"="Santé publique",  
             "Austerite"="Austérité",  
             "AppartParti"="Appartenance \npartisane",  
             "SystemeSante"="Système de \nsanté",  
             "ConditEco"="Conditions \néconomiques"))
```

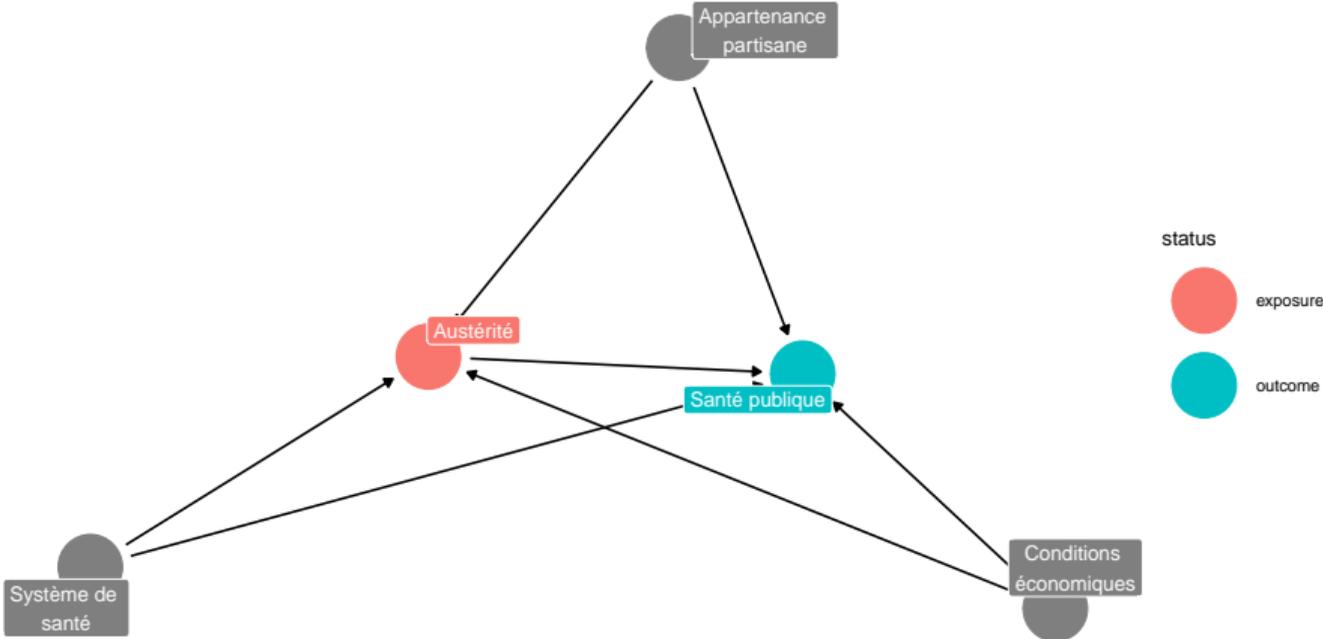
## La marche à suivre

- ▶ Pour chaque variable on recense simplement **toutes les variables, observées ou non, qui doivent apparaître comme cause directe de celle-ci**
  - ▶ ce n'est pas une décision fondée sur les données dont on dispose
  - ▶ c'est une **décision essentiellement théorique** fondée sur :
    - ▶ la théorie sociologique de l'objet particulier que l'on étudie
    - ▶ la littérature antérieure disponible
- ▶ La **représentation graphique** est ensuite générée par la fonction `ggdag`
  - ▶ Ici j'ai rajouté quelques améliorations pour la rendre visuellement plus agréable, voir le site pour les détails du code

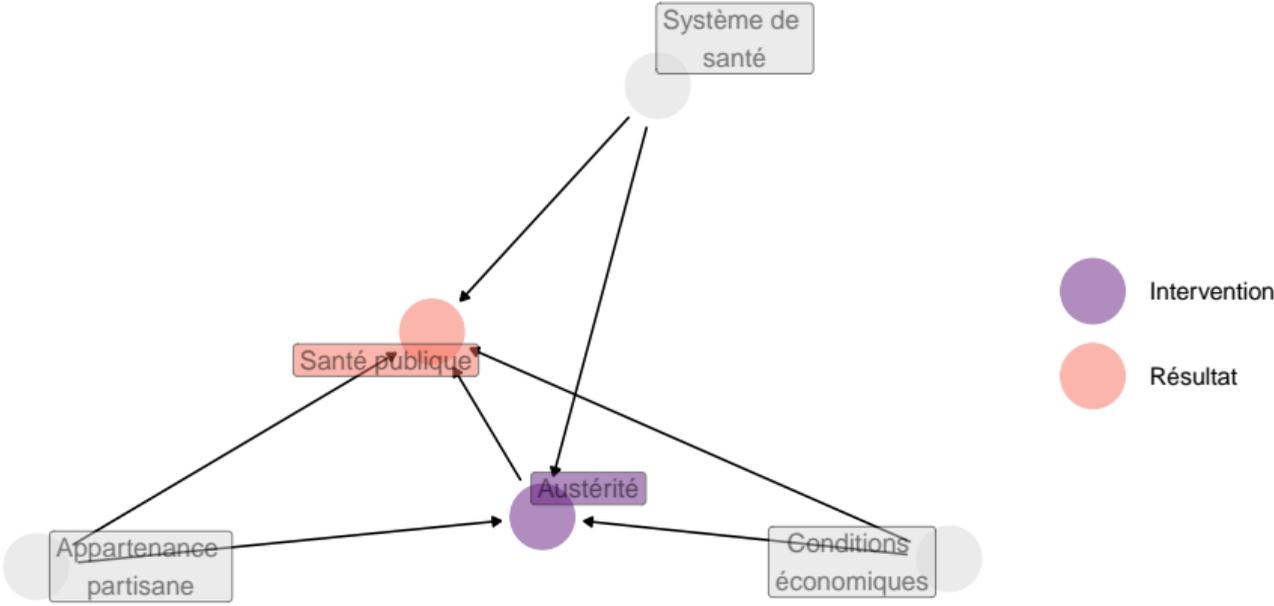
## Ce que donne la fonction ggdag

```
graph_jacques_obtenu_par_ggdag<-  
  ggdag_status(graph_jacques,  
               text=FALSE,  
               use_labels = "label",  
               label_size=5)+  
  #J'utilise en fait ggdag_status qui met distingue la variable d'intérêt  
  # et l'intervention  
  theme_void()
```

# Ce que donne la fonction ggdag



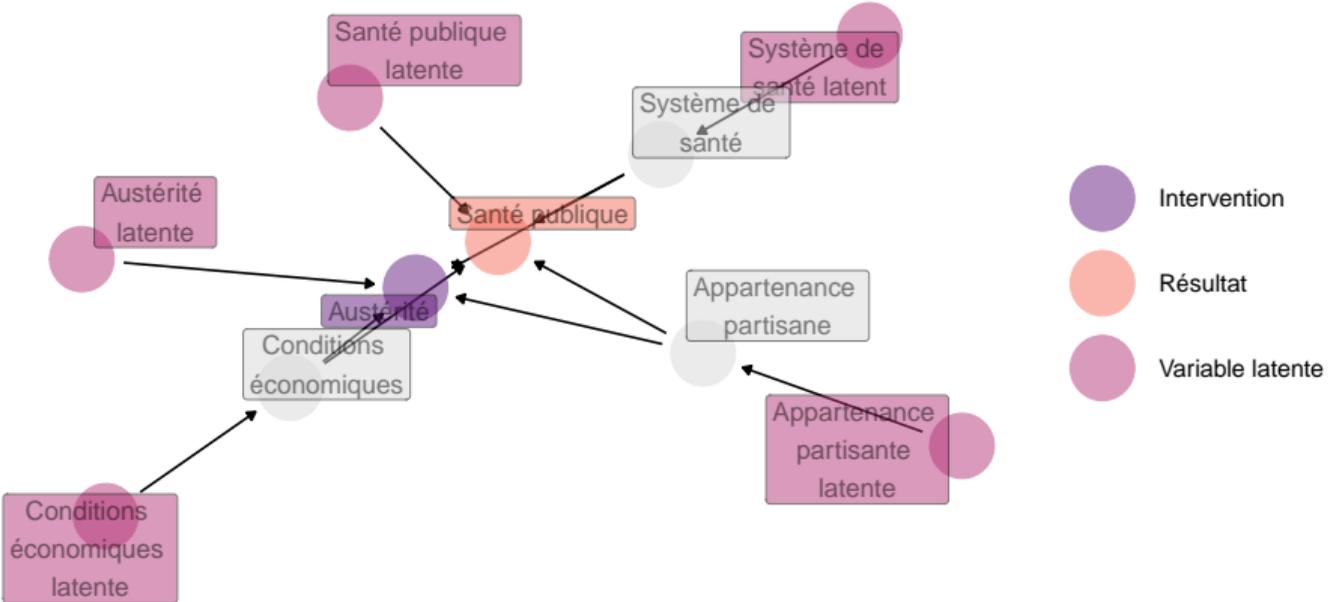
# Avec un peu de travail supplémentaire



## Représenter les variables inobservées ?

- ▶ Ici le graphe ne représente pas de **variables inobservées**
- ▶ Dans l'approche proposée par Pearl (2009), on garde en général **implicites** les variables inobservées (“latentes”) *qui ne sont causes que d'une seule variable*
  - ▶ Chaque variable observée est toujours supposée dépendre d'*une variable inobservée, indépendante de toutes les autres variables du problème*, en plus de toutes celles représentées par les flèches qui aboutissent au nœud qui lui correspond
- ▶ On peut choisir de les représenter **sans changer la signification** du graphe du point de vue des outils que l'on va mobiliser ensuite
- ▶ Représenter toutes les variables inobservées qui n'aboutissent chacune qu'à une seule variable observée est parfois appelé **magnification**

Ce graphe est strictement équivalent au précédent mais beaucoup plus difficile à lire



## Que signifient ces flèches ?

- ▶ **Pas d'hypothèse de constance ou de linéarité des effets !** Relation aussi générale qu'il est possible de l'être → rejoint l'hypothèse d'effets causaux hétérogènes chez Rubin
- ▶ Quand on code `SantePub~Austerite+AppartParti+SystemeSante+ConditEco`, on dit qu'il existe :

- ▶ une fonction (inconnue)  $f^{SantePub}$
- ▶ une variable latente  $LatSantePub$  indépendante de toutes les autres variables, observées ou latentes telles que :

$$SantePub = f^{SantePub}(Austerite, AppartParti, SystemeSante, ConditEco; LatSantePub)$$

## Le champ auquel s'appliquent ces techniques : les graphes acycliques

- ▶ Un graphe est **cyclique** si en partant d'un nœud et en suivant successivement des flèches, dans le bon sens, on pourrait revenir à ce nœud
- ▶ **Les graphes cycliques ne sont pas couverts par les techniques fondées sur les représentations graphiques**
- ▶ Cela exclut le cas de la **simultanéité** ( $X$  cause  $Y$  qui cause  $X$ )

## Pouvez-vous proposer des exemples généraux de graphes cycliques ?

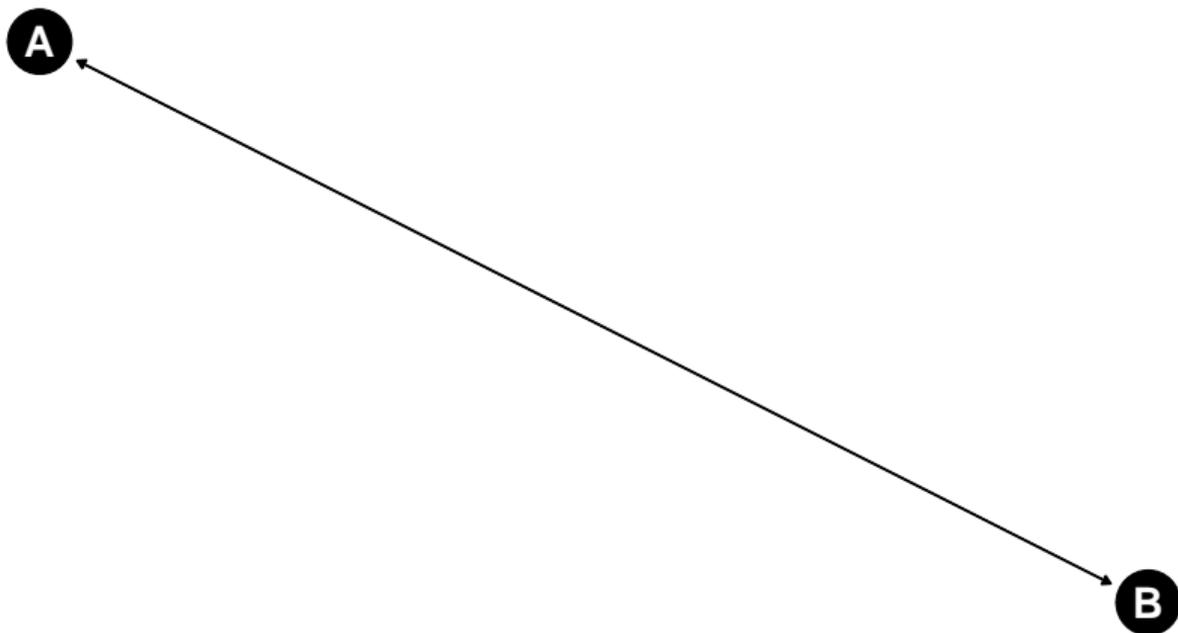
- ▶ Pas besoin de spécifier des noms de variables, **c'est seulement la forme qui importe**
- ▶ Avec 2 ou 3 nœuds pour commencer
- ▶ Construisez les à partir des fonctions du package `ggdag`

## Exemples de graphes cycliques : avec deux variables

```
library(ggdag)

cycle2<-dagify(A~B,
               B~A)
```

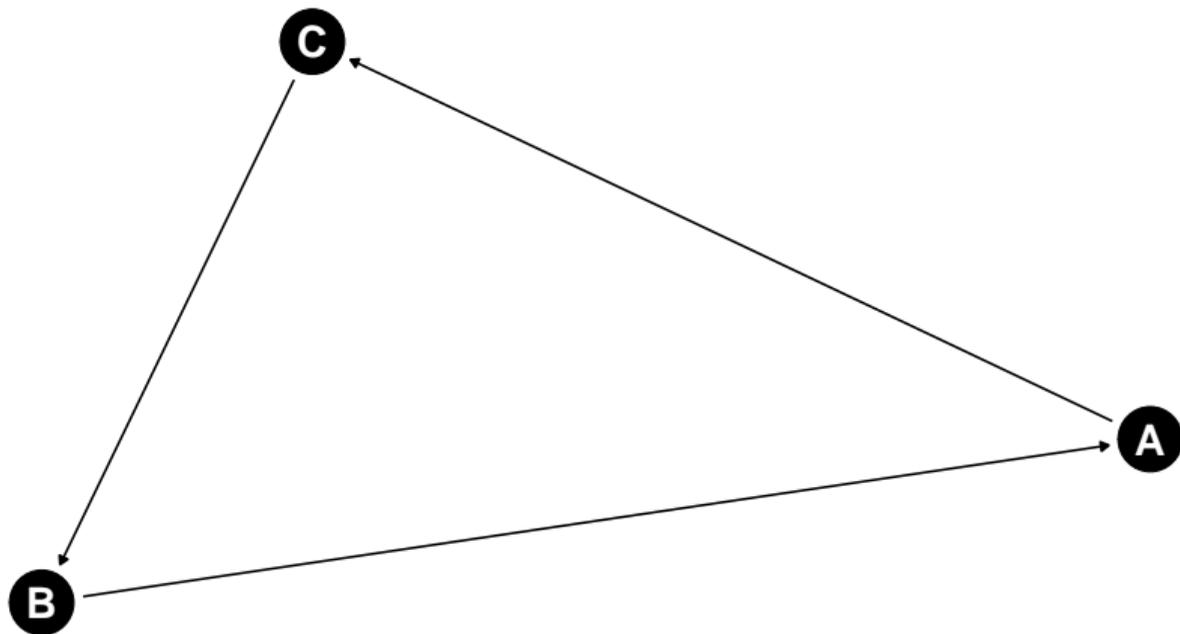
## Exemples de graphes cycliques : avec deux variables



## Exemples de graphes cycliques : avec trois variables

```
cycle3<-dagify(A~B,  
               B~C,  
               C~A)
```

## Exemples de graphes cycliques : avec trois variables



## Un peu de vocabulaire sur ces représentations graphiques

- ▶ **Grphe acyclique orienté** (*directed acyclic graph* en anglais)
- ▶ Vocabulaire de la **parenté** appliquée aux nœuds / variables
- ▶ **Chemin** : succession de flèches (pas nécessairement dans le même sens) pour aller d'une variable à une autre
- ▶ **Chemin orienté** : toutes les flèches vont dans le même sens

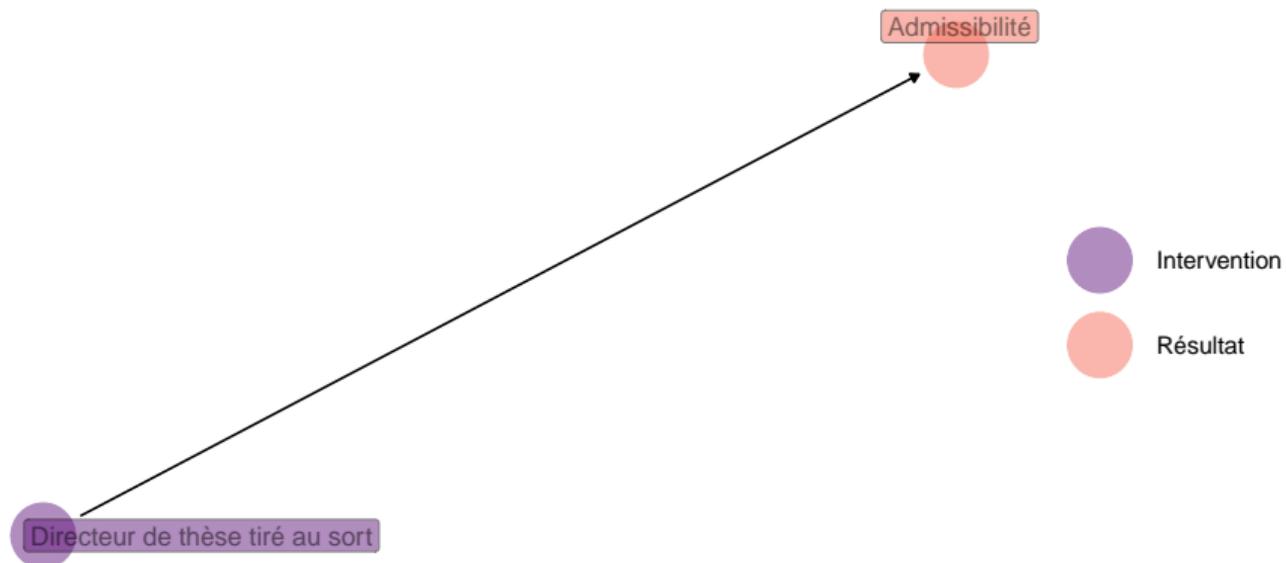
## Quel est le graphe d'une expérience naturelle ?

- ▶ Supposez que vous étudiez une **expérience naturelle**
- ▶ Par exemple Godechot (2016) : pour les recrutements à l'EHESS, premier classement des dossiers effectué par une commission tirée au sort à laquelle peut appartenir le directeur de thèse des candidats
- ▶ Quel est le graphe à considérer dans cette situation ?
- ▶ Construisez le à l'aide du package `ggdag`

## Quel est le graphe d'une expérience naturelle ?

```
graph_godechot<-dagify(Admissib~DirThese,  
  #Pour chaque nœuds auquel aboutit au moins une flèche,  
  # on recense d'où partent toutes ces flèches  
  exposure = "DirThese",  
  #La variable qui correspond à l'intervention dont on  
  # souhaite étudier les effets  
  outcome = "Admissib",  
  #La variable qui correspond aux conséquences que l'on  
  # voudrait pouvoir mesurer  
  labels = c("DirThese"="Directeur de thèse tiré au sort",  
             "Admissib"="Admissibilité"))  
  #Des labels pour rendre les choses plus lisibles
```

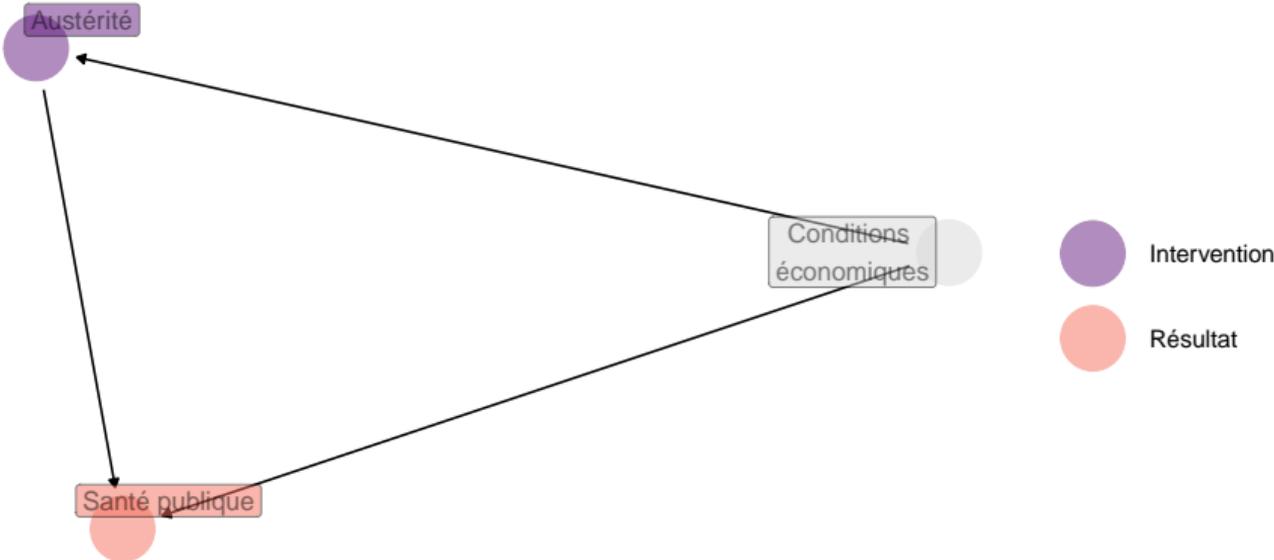
## Quel est le graphe d'une expérience naturelle ?



## Graphe d'une expérience naturelle : justification

- ▶ Bien entendu l'admissibilité dépend d'énormément des facteurs différents
- ▶ Mais la commission qui prend la décision est tirée au sort on sait que la présence du directeur de thèse dans le jury est indépendante de tous ces autres facteurs
- ▶ On peut tous les **résumer en une variable latente indépendante** de toutes les autres variables du problème
- ▶ On n'a en fait **pas besoin de représenter explicitement** cette variable latente

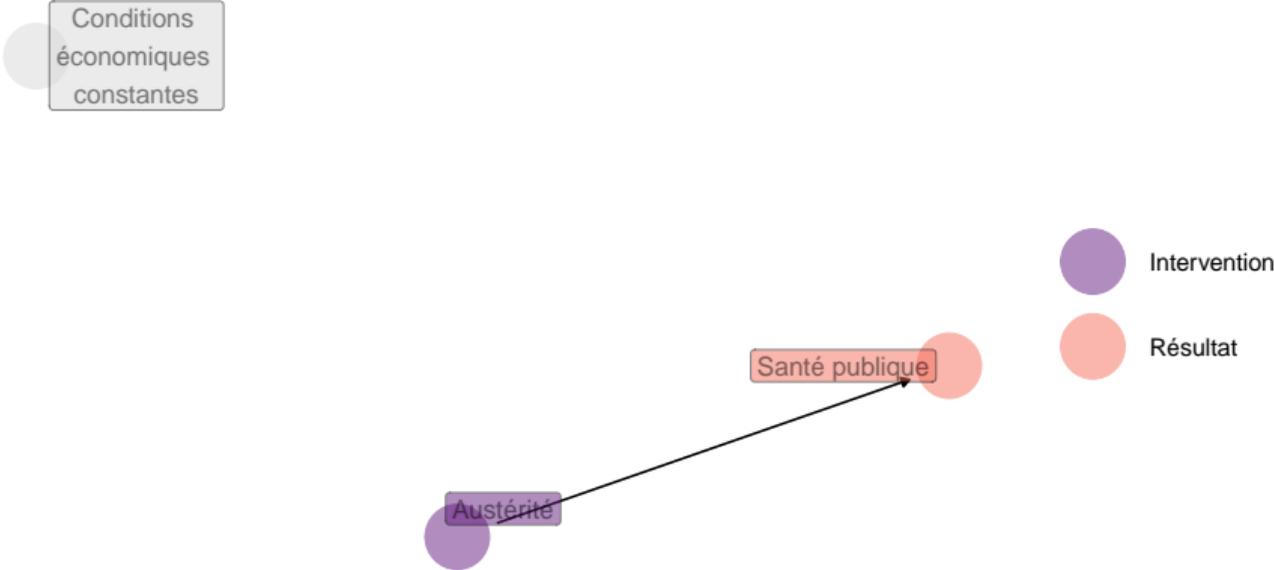
# Pourquoi conditionner sur une variable observable? Un graphe simplifié à partir de Jacques and Noël (2022)



## Pourquoi conditionner sur une variable observable ? Un graphe simplifié à partir de Jacques and Noël (2022)

- ▶ Comment ce graphe doit-il être transformé si on raisonne **à l'intérieur d'une strate** de pays qui font tous face aux mêmes conditions économiques ?
- ▶ En d'autres termes si l'on **conditionne** sur les conditions économiques ?

# Pourquoi conditionner sur une variable observable? Quand on raisonne à conditions économiques identiques entre pays



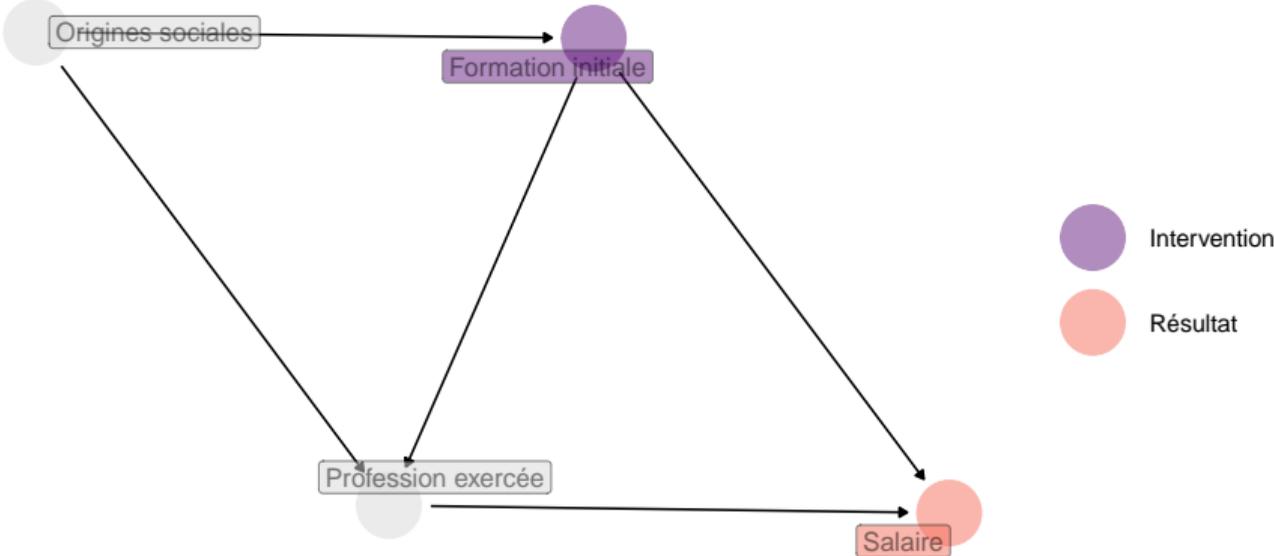
## Pourquoi conditionner sur une variable observable? Quand on raisonne à conditions économiques identiques entre pays

- ▶ Les conditions économiques **ne varient pas d'un pays à l'autre**
- ▶ Il n'y a donc pas de sens à les faire figurer comme cause de l'austérité
- ▶ Ni comme cause du niveau et de la structure de la dépense de santé publique
- ▶ On peut enlever toutes les flèches qui partent de cette variable
- ▶ Pour autant qu'on s'intéresse seulement à l'austérité et à la dépense de santé publique, **c'est comme si on regardait une expérience naturelle**
- ▶ Autrement dit : **le graphe de départ équivaut à l'hypothèse d'indépendance conditionnelle**
- ▶ Il justifie donc de conditionner sur les conditions économiques pour **identifier les effets causaux moyens** de l'austérité sur le niveau et la structure de la dépense de santé publique

## Encore un peu de vocabulaire : les portes de sortie

- ▶ **Porte de sortie** (*backdoor* en anglais) : chemin *non-orienté* qui lie l'intervention et la variable d'intérêt, et dont une extrémité est **une flèche qui débouche sur l'intervention**
- ▶ C'est donc un chemin qui aboutit à la variable d'intérêt mais qui **contient une des causes de l'intervention**
- ▶ Ici le chemin *Austérité* ← *Conditions économiques* → *Santé publique* est une porte de sortie
- ▶ Conditionner sur les conditions économiques, c'est-à-dire comparer des pays connaissant les mêmes conditions économiques permet de **bloquer la porte de sortie**
- ▶ C'est-à-dire de neutraliser la part de la corrélation entre austérité et dépense de santé publique qui vient du fait qu'elles ont une cause commune
- ▶ Cela permet en définitive d'identifier les effets causaux moyens de l'austérité sur la dépense de santé publique

# Faut-il toujours conditionner sur les caractéristiques observables ? Un exemple hypothétique



## Faut-il toujours conditionner sur les caractéristiques observables ?

- ▶ Ici on a **trois chemins** qui lient l'intervention et la variable d'intérêt
  - ▶ le **chemin direct** : Formation initiale  $\rightarrow$  Salaire
  - ▶ la **porte de sortie** : Formation initiale  $\leftarrow$  Origines sociales  $\rightarrow$  Profession exercée  $\rightarrow$  Salaire
  - ▶ le chemin Formation initiale  $\rightarrow$  Profession exercée  $\rightarrow$  Salaire
- ▶ On appelle ce dernier chemin une **chaîne de médiation**
  - ▶ un chemin orienté qui part de l'intervention et aboutit à la variable d'intérêt

## Faut-il toujours conditionner sur les caractéristiques observables ? Non : ne pas bloquer les chaînes de médiation

- ▶ Si on veut connaître les effets causaux moyens de l'intervention, **on ne veut surtout pas bloquer les chaînes de médiation !**
  - ▶ C'est une question différente et différente de savoir quelle part de ces effets causaux passe par quel chemin → **analyse de médiation**, sujet non-traité ici mais important pour étudier les mécanismes sociologiques mis en jeu
- ▶ Dans le cas présent : on va conditionner sur les origines sociales mais **pas sur la profession exercée**
- ▶ Typiquement ici conditionner sur la profession exercée conduirait à sous-estimer les effets causaux moyens de la formation initiale sur le salaire

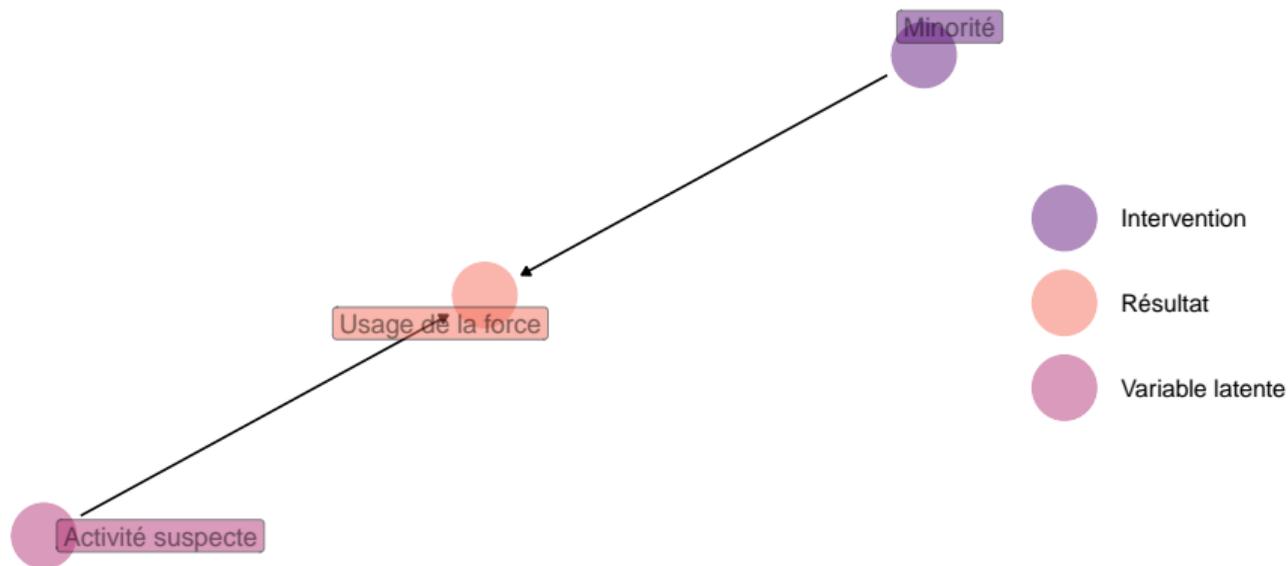
# Faut-il toujours conditionner sur les caractéristiques observables ?

## L'exemple des violences policières aux Etats-Unis

- ▶ Débat important sur les violences policières et la persistance du racisme aux Etats-Unis
- ▶ Question essentielle : l'usage de la force par la police étatsunienne est-il influencé par des biais racistes ?
  - ▶ C'est une **question causale** : dans la rencontre entre un policier et un civil, la perception du civil par le policier comme relevant d'une catégorie ethno-raciale ou d'une autre conduit-elle à des décisions différentes
- ▶ Knox, Lowe, and Mummolo (2020) synthétisent une longue littérature qui montre que, parmi les civils faisant l'objet d'un contrôle, **la fréquence d'usage de la force n'est pas plus grande contre des civils Noirs américains que contre des civils Blancs**
- ▶ Est-ce une bonne façon d'identifier ces effets causaux moyens ?

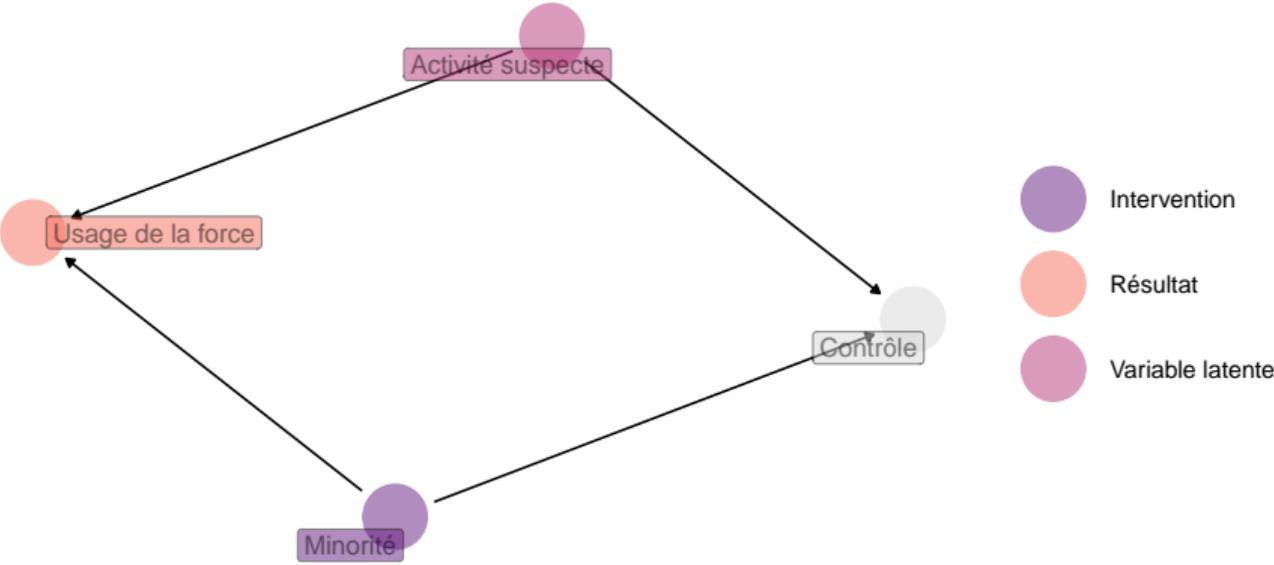
Faut-il toujours conditionner sur les caractéristiques observables ?

L'exemple des violences policières aux Etats-Unis : ce que l'on croit qu'on fait



# Faut-il toujours conditionner sur les caractéristiques observables ?

L'exemple des violences policières aux Etats-Unis : ce que l'on fait vraiment



# Faut-il toujours conditionner sur les caractéristiques observables ?

## L'exemple des violences policières aux Etats-Unis : les conséquences du conditionnement sur le contrôle

- ▶ Si **des biais racistes sont également présents dans la décision de contrôler**
  - ▶ c'est-à-dire si pour des activités également susceptibles de mener à un contrôle, les Noirs sont bien plus souvent contrôlés
- ▶ Alors la population des **civils faisant l'objet d'un contrôle** comprend (grossièrement) :
  - ▶ des Blancs dont l'activité semblerait suspecte quelle que soit la catégorie raciale
  - ▶ des Noirs dont l'activité semblerait suspecte quelle que soit la catégorie raciale
  - ▶ des Noirs dont l'activité ne paraîtrait pas suspecte s'ils étaient Blancs

## Faut-il toujours conditionner sur les caractéristiques observables ?

### L'exemple des violences policières aux Etats-Unis : les conséquences du conditionnement sur le contrôle

- ▶ Au sein d'un groupe ainsi constitué il est attendu que l'usage de la force ne soit pas plus fréquent contre les Noirs que contre les Blancs
  - ▶ mais **cela ne signifie en rien que l'usage de la force n'est pas biaisé racialement**
- ▶ Il faudrait donc ne pas conditionner !
  - ▶ En d'autres termes **travailler sur toute la population des interactions entre policiers et civils**, et pas seulement sur celles qui conduisent à un contrôle
- ▶ Pas forcément faisable en pratique : voir l'article de Knox, Lowe, and Mummolo (2020) pour des solutions statistiques (sujet non-traité ici)

## Faut-il toujours conditionner sur les caractéristiques observables? Non : ne pas créer de biais de collision

- ▶ Ici le problème vient du fait que l'on conditionne sur la **fourchette inversée**  
Minorité → Contrôle ← Activité suspecte
- ▶ Ce conditionnement génère une corrélation qui n'a pas d'interprétation causale entre la catégorie raciale et l'activité potentiellement suspecte
- ▶ Cette corrélation non-causale est parfois appelée **biais de collision** (*collider bias* en anglais)
- ▶ **Il est très important de l'éviter !**

## Comment choisir les variables de conditionnement ? Un premier bilan

- ▶ **Conditionner sur une ou plusieurs variables observables** permet parfois d'**identifier des effets causaux moyens**
- ▶ Conditionner sur certaines variables observables peut au contraire **empêcher cette identification**, en particulier si :
  - a. ces variables sont des **médiateurs** de l'effet de l'intervention sur la dimension d'intérêt
  - b. conditionner sur ces variables crée une **corrélacion** entre des variables non-apparentées, parce que l'on fait apparaître ainsi un **biais de collision**

## Stratégie *backdoor*

- ▶ C'est la stratégie qui permet de **choisir l'ensemble des variables de conditionnement**
- ▶ Un tel ensemble (*éventuellement vide*) de variables doit à la fois (i) bloquer toutes les **portes de sortie** qui débouchent sur l'intervention et (ii) ne bloquer aucune des **chaînes de médiation** qui vont de l'intervention au résultat étudié.
- ▶ Une porte de sortie débouchant sur l'intervention est bloquée si :
  - ▶ elle contient une flèche qui aboutit à une des variables sur laquelle on conditionne  
 $A \rightarrow X$
  - ▶ elle contient deux flèches qui partent d'une variable sur laquelle on conditionne  
 $A \leftarrow X \rightarrow B$
  - ▶ elle contient une fourchette inversée  $A \rightarrow Z \leftarrow B$  telle que ni  $Z$  ni aucun de ses descendants n'appartienne à l'ensemble des variables sur lesquelles on conditionne

## Stratégie *backdoor* : quelques remarques

- ▶ **Solution parfois multiple** → plusieurs choix d'ensemble de variables sur lesquelles il est possible de conditionner pour identifier des effets causaux
- ▶ **Pas toujours besoin de conditionner** → l'ensemble vide est solution et la comparaison des individus selon les valeurs prises par la variable représentant l'intervention suffit à en identifier les effets causaux moyens
- ▶ **Pas toujours de solution** → l'ensemble des solutions peut être vide

⚠ les deux derniers points ne veulent pas dire la même chose

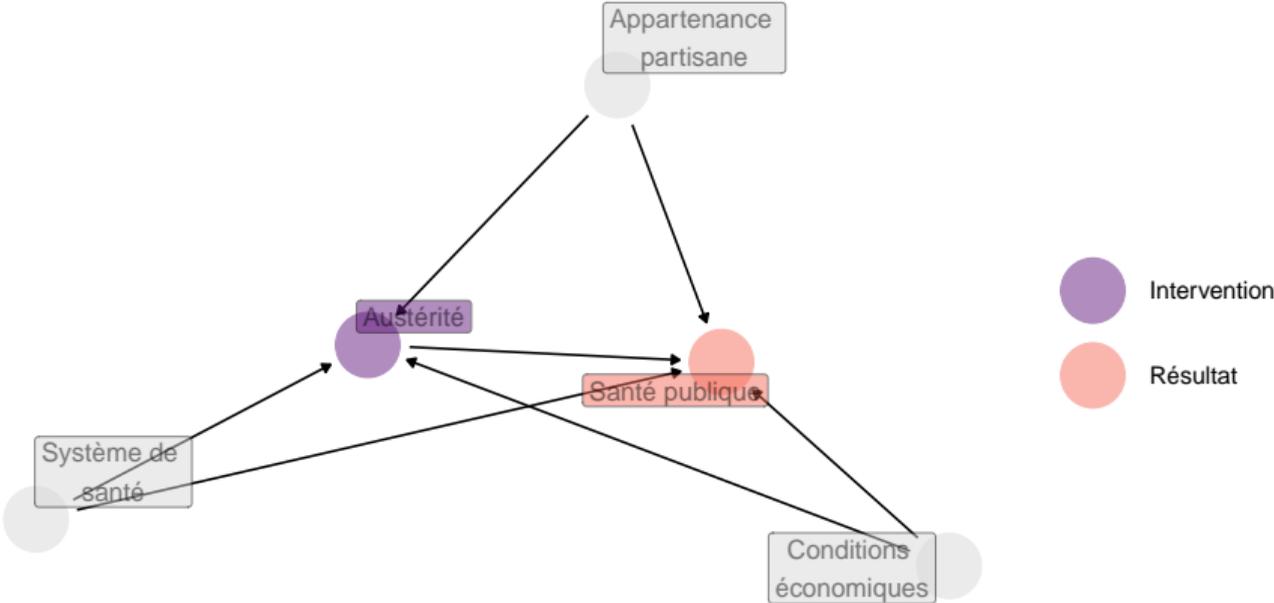
## Stratégie *backdoor* : en pratique ?

- ▶ **Un jeu de règles simples** mais fastidieux à appliquer quand on est dans un cas un peu complexe
  - ▶ On aurait éventuellement besoin de vérifier tous les ensembles de variables de conditionnement possibles pour vérifier lesquels respectent ces règles et peuvent être retenus
- ▶ Pourquoi des informaticiens se sont intéressés à l'application de ce formalisme aux relations causales ?
  - ▶ **Les graphes orientés sont un objet très usuel pour les informaticiens**
  - ▶ Développement d'**algorithmes efficaces** permettant de déterminer automatiquement les solutions possibles au problème à partir de la donnée du graphe
  - ▶ On peut les invoquer avec le **package** `ggdag` !

## La fonction `dag_adjustment_sets` du package `ggdag`

- ▶ **Prend en entrée un graphe**
- ▶ **Renvoie l'ensemble des solutions *minimales* du problème**
  - ▶ Ces solutions sont elles-mêmes des ensembles !
- ▶ **Solutions minimales ?**
  - ▶ Minimales au sens de l'inclusion
  - ▶ Il n'existe pas d'ensemble de variables de conditionnement qui soit strictement inclus dans une solution minimale et qui soit solution du problème
  - ▶ Intéressant d'avoir des solutions minimales en vue de l'estimation → discussion de la semaine prochaine : **plus on a de variables à considérer plus la mise en pratique du conditionnement est difficile**

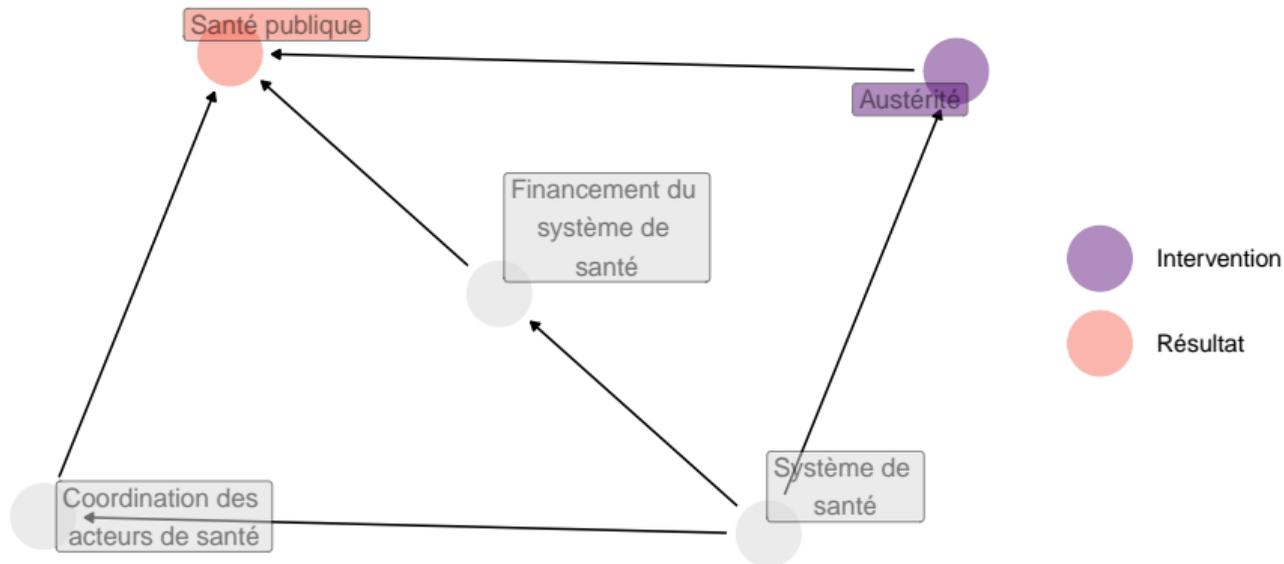
Le graphe tiré de Jacques and Noël (2022). Déterminer les solutions possibles à l'aide de dag\_adjustment\_sets



## Le graphe tiré de Jacques and Noël (2022). Déterminer les solutions possibles à l'aide de dag\_adjustment\_sets

```
graph_jacques<-dagify(SantePub~Austerite+AppartParti+SystemeSante+ConditEco,  
  #Pour chaque nœuds auquel aboutit au moins une flèche,  
  # on recense d'où partent toutes ces flèches  
  Austerite~AppartParti+SystemeSante+ConditEco,  
  exposure = "Austerite",  
  #La variable qui correspond à l'intervention dont on  
  # souhaite étudier les effets  
  outcome = "SantePub")  
  #La variable qui correspond aux conséquences que l'on  
  # voudrait pouvoir mesurer  
  
#On récupère un ensemble de variables de conditionnement  
conditionner<-data.table(dag_adjustment_sets(graph_jacques)[[1]])  
levels(factor(conditionner$set))  
  
## [1] "{AppartParti, ConditEco, SystemeSante}"
```

Un exemple inspiré de Jacques and Noël (2022). Déterminer les solutions possibles à l'aide de dag\_adjustment\_sets



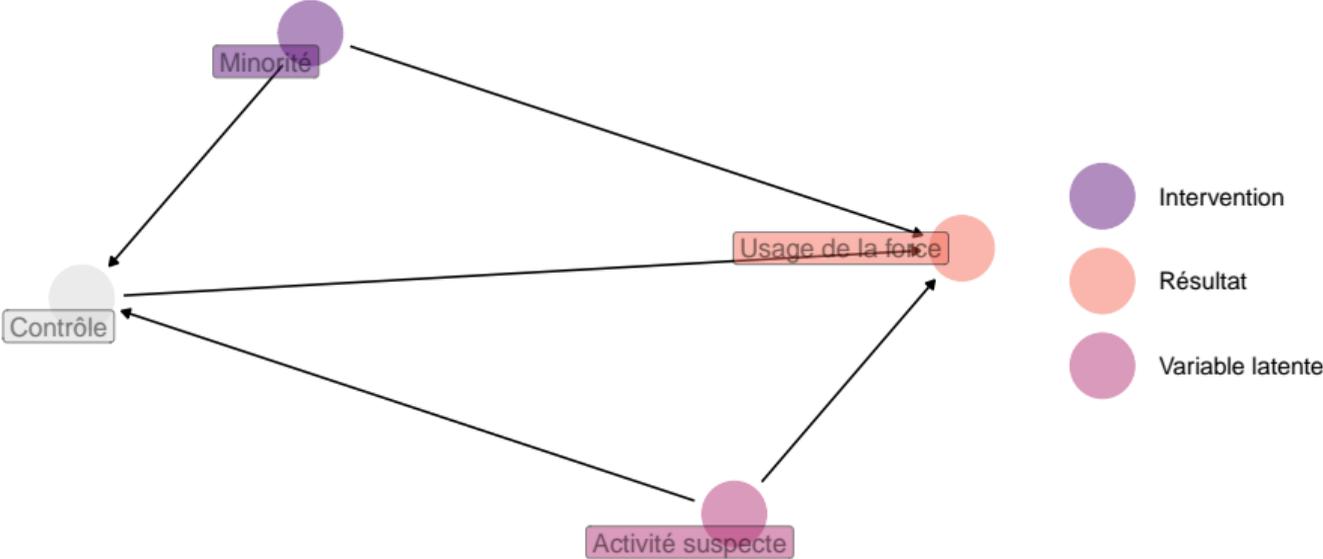
Un exemple inspiré de Jacques and Noël (2022). Déterminer les solutions possibles à l'aide de `dag_adjustment_sets`

```
graph_jacques_multiple<-
  dagify(SantePub~Austerite+DiffFinanceSysSan+CoordActSante,
        Austerite~SystemeSante,
        DiffFinanceSysSan~SystemeSante,
        CoordActSante~SystemeSante,
        exposure = "Austerite",
        outcome = "SantePub")

#On récupère un ensemble d'ensembles de variables de conditionnement
conditionner<-
  data.table(dag_adjustment_sets(graph_jacques_multiple)[[1]])
levels(factor(conditionner$set))

## [1] "{CoordActSante, DiffFinanceSysSan}" "{SystemeSante}"
```

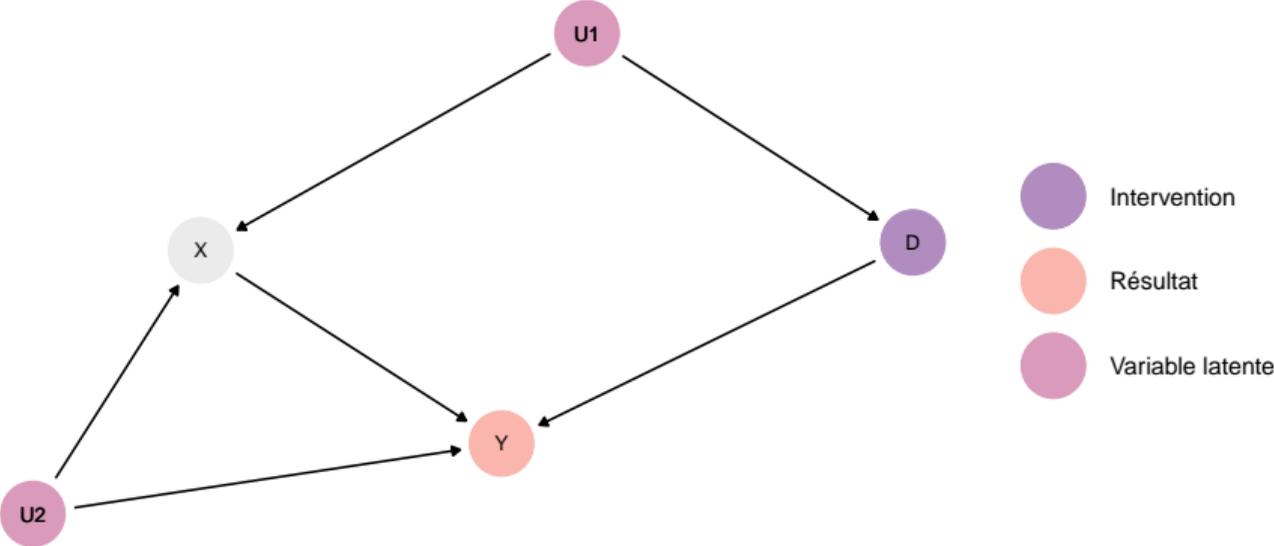
Un exemple inspiré de Knox, Lowe, and Mummolo (2020). Déterminer les solutions possibles à l'aide de dag\_adjustment\_sets



## Un exemple inspiré de Knox, Lowe, and Mummolo (2020). Déterminer les solutions possibles à l'aide de `dag_adjustment_sets`

```
dag_race_force_complete<-dagify(force ~ race + suspicion + stop,  
                                stop ~ race + suspicion,  
                                exposure="race",  
                                outcome="force",  
                                latent="suspicion",  
                                labels=c("race"="Minorité",  
                                          "suspicion"="Activité suspecte",  
                                          "force"="Usage de la force",  
                                          "stop"="Contrôle"))  
  
#On récupère un ensemble d'ensembles de variables de conditionnement  
conditionner<-  
  data.table(dag_adjustment_sets(dag_race_force_complete)[[1]])  
levels(factor(conditionner$set))  
  
## [1] "{(Backdoor Paths Unconditionally Closed)}"
```

Un exemple fictif. Déterminer les solutions possibles à l'aide de `dag_adjustment_sets`



## Un exemple fictif. Déterminer les solutions possibles à l'aide de dag adjustment sets

```
dag_fict<-dagify(Y ~D + U2 +X,  
               D~U1,  
               X~U1+U2,  
               exposure = "D",  
               outcome = "Y",  
               latent = c("U1","U2"))
```

*#On récupère un ensemble de variables de conditionnement*

```
conditionner<-data.table(dag_adjustment_sets(dag_fict)[[1]])
```

```
## Warning in dag_adjustment_sets(dag_fict): Failed to close backdoor paths. Comm  
##           * graph is not acyclic  
##           * backdoor paths are not closeable with given set of variables  
##           * necessary variables are unmeasured (latent)
```

```
levels(factor(conditionner$set))
```

```
## [1] "{(No Way to Block Backdoor Paths)}"
```

## Une conclusion pour aujourd'hui

- ▶ **Un concept à peu près opérationnel de causalité pour les sciences sociales quantitatives**
  - ▶ Conception **interventionniste** de la causalité
  - ▶ Place centrale de l'**expérience aléatoire contrôlée** et de l'**expérience naturelle**

## Une conclusion pour aujourd'hui

- ▶ Définition raisonnable de ce que c'est que **contrôler de  $X$** 
  - ▶ **Conditionner** : comparer entre eux des individus qui ont la même valeur de  $X$
  - ▶ Identifie les effets causaux moyens de l'intervention sous une **hypothèse d'indépendance conditionnelle**

## Une conclusion pour aujourd'hui

- ▶ **Une approche graphique et algorithmique pour déterminer sur quelles variables on veut conditionner**
  - ▶ Bloquer les portes de sortie
  - ▶ Attention au biais de collision et aux chaînes de médiation

## Au programme pour la semaine prochaine

- ▶ On sait sur quelles variables observables on veut conditionner
- ▶ En théorie conditionner a l'air très simple
- ▶ Mais en pratique. . .

## Bibliographie

## Bibliographie I

- Bickel, P. J., E. A. Hammel, and J. W. O'Connell. 1975. "Sex Bias in Graduate Admissions : Data from Berkeley." *Science* 187 (4175) : 398–404.  
<https://doi.org/10.1126/science.187.4175.398>.
- Godechot, Olivier. 2016. "The Chance of Influence : A Natural Experiment on the Role of Social Capital in Faculty Recruitment." *Social Networks* 46 : 60–75.  
<https://doi.org/https://doi.org/10.1016/j.socnet.2016.02.002>.
- Holland, Paul W. 1986. "Statistics and Causal Inference." *Journal of the American Statistical Association* 81 (396) : 945–60.
- Jacques, Olivier, and Alain Noël. 2022. "The Politics of Public Health Investments." *Social Science & Medicine* 309 : 115272.  
<https://doi.org/https://doi.org/10.1016/j.socscimed.2022.115272>.

## Bibliographie II

- Knox, Dean, Will Lowe, and Jonathan Mummolo. 2020. "Administrative Records Mask Racially Biased Policing." *American Political Science Review*.  
[https://www.cambridge.org/core/journals/american-political-science-review/article/administrative-records-mask-racially-biased-policing/66BC0F9998543868BB20F241796B79B8?utm\\_source=hootsuite/&utm\\_medium=twitter/&utm\\_term=/&utm\\_content=FirstView/&utm\\_campaign=PS](https://www.cambridge.org/core/journals/american-political-science-review/article/administrative-records-mask-racially-biased-policing/66BC0F9998543868BB20F241796B79B8?utm_source=hootsuite/&utm_medium=twitter/&utm_term=/&utm_content=FirstView/&utm_campaign=PS).
- Pearl, Judea. 2009. *Causality*. Cambridge University Press.
- Piketty, Thomas. 2019. *Capital Et Idéologie*. Paris : Le Seuil.
- Rubin, Donald B. 1974. "Estimating Causal Effects of Treatments in Randomized and Nonrandomized Studies." *Journal of Educational Psychology* 66 (5) : 688.
- Splawa-Neyman, Jerzy, D. M. Dabrowska, and T. P. Speed. 1990. "On the Application of Probability Theory to Agricultural Experiments. Essay on Principles. Section 9." *Statistical Science* 5 (4) : 465–72.