


cours 4  
Apprentissage de structure  
de réseau bayésien

# ① Algorithme fondé sur les contraintes

## Apprentissage du squelette


- 1  $\mathcal{G} \leftarrow$  graphe non orienté complet
- 2  $d \leftarrow 0$  // taille de l'ensemble de conditionnement
- 3  $SepSet_{XY} \leftarrow \emptyset$  pour tout couple de nœuds  $X, Y$
- 4 **répéter**
- 5     **pour chaque** couple  $(X, Y)$  t.q.  $X - Y \in \mathcal{G}$  et  $|\mathbf{Adj}(X) \setminus \{Y\}| \geq d$  **faire**
- 6         **répéter**
- 7             Choisir un  $\mathbf{Z} \subseteq \mathbf{Adj}(X) \setminus \{Y\}$  t.q.  $|\mathbf{Z}| = d$
- 8             **si**  $X \perp\!\!\!\perp_P Y | \mathbf{Z}$  **alors**
- 9                 Supprimer l'arête  $X - Y$  de  $\mathcal{G}$
- 10                  $SepSet_{XY} \leftarrow \mathbf{Z}$
- 11                 break
- 12             **jusqu'à** Tous les  $\mathbf{Z}$  de taille  $d$  ont été testés;
- 13      $d \leftarrow d + 1$
- 14 **jusqu'à**  $|\mathbf{Adj}(X)| \leq d$  pour tout nœud  $X$ ;

## Exemple d'application (1/3)




RB réel

# Exemple d'application (1/3)




RB réel




$\mathcal{G}$  complet


# Exemple d'application (1/3)



RB réel




$\mathcal{G}$  complet




$\perp\!\!\!\perp$  ordre  $d = 0$

- ▶  $A \perp\!\!\!\perp B, A \perp\!\!\!\perp L, A \perp\!\!\!\perp S$
- ▶  $B \perp\!\!\!\perp T$
- ▶  $L \perp\!\!\!\perp T$
- ▶  $S \perp\!\!\!\perp T$

## Exemple d'application (2/3)




RB réel




$\perp\!\!\!\perp$  ordre  $d = 0$


## Exemple d'application (2/3)



RB réel



$\perp\!\!\!\perp$  ordre  $d = 0$




$\perp\!\!\!\perp$  ordre  $d = 1$


- ▶  $A \perp\!\!\!\perp D | T, A \perp\!\!\!\perp O | T$
- ▶  $A \perp\!\!\!\perp X | T, B \perp\!\!\!\perp L | S$
- ▶  $B \perp\!\!\!\perp O | S, B \perp\!\!\!\perp X | S$
- ▶  $D \perp\!\!\!\perp X | O, L \perp\!\!\!\perp X | O$
- ▶  $O \perp\!\!\!\perp S | L, S \perp\!\!\!\perp X | L$
- ▶  $T \perp\!\!\!\perp X | O$



## Exemple d'application (3/3)




RB réel




$\perp\!\!\!\perp$  ordre  $d = 1$


# Exemple d'application (3/3)



RB réel



$\perp\!\!\!\perp$  ordre  $d = 1$



$\perp\!\!\!\perp$  ordre  $d = 2$

- ▶  $D \perp\!\!\!\perp L \mid \{O, B\}$
- ▶  $D \perp\!\!\!\perp S \mid \{O, B\}$
- ▶  $D \perp\!\!\!\perp T \mid \{O, S\}$

## Définition

- ▶ **unshielded triple** : triplet  $\langle X, Z, Y \rangle$  de nœuds de  $\mathcal{G}$  t.q. :
  - ▶  $X - Z - Y \in \mathcal{G}$
  - ▶  $X - Y \notin \mathcal{G}$
- ▶ équivalent non orienté d'une v-structure

## Définition

- ▶ **unshielded triple** : triplet  $\langle X, Z, Y \rangle$  de nœuds de  $\mathcal{G}$  t.q. :
  - ▶  $X - Z - Y \in \mathcal{G}$
  - ▶  $X - Y \notin \mathcal{G}$
- ▶ équivalent non orienté d'une v-structure

## Orientation des arêtes

- 1 // 1. Orientation des v-structures
- 2  $\mathcal{G}_{PDAG} \leftarrow \mathcal{G}$
- 3 **pour chaque unshielded triple**  $\langle X, Z, Y \rangle$  **de**  $\mathcal{G}$  **faire**
- 4     **si**  $Z \notin \text{SepSet}_{XY}$  **alors**
- 5         **R0** : dans  $\mathcal{G}_{PDAG}$ , remplacer  $X - Z$  et  $Z - Y$  par  $X \rightarrow Z$  et  $Z \leftarrow Y$

## Définition

- ▶ **unshielded triple** : triplet  $\langle X, Z, Y \rangle$  de nœuds de  $\mathcal{G}$  t.q. :
  - ▶  $X - Z - Y \in \mathcal{G}$
  - ▶  $X - Y \notin \mathcal{G}$
- ▶ équivalent non orienté d'une v-structure

## Orientation des arêtes

1 // 1. Orientation des v-structures

2  $\mathcal{G}_{PDAG} \leftarrow \mathcal{G}$

3 **pour chaque unshielded triple**  $\langle X, Z, Y \rangle$  **de**  $\mathcal{G}$  **faire**


4     **si**  $Z \notin \text{SepSet}_{XY}$  **alors**

5     |     **R0** : dans  $\mathcal{G}_{PDAG}$ , remplacer  $X - Z$  et  $Z - Y$  par  $X \rightarrow Z$  et  $Z \leftarrow Y$


$\implies \mathcal{G}_{PDAG} = \text{squelette} + \text{v-structures} = \text{pattern}$

4 règles de propagation :

pas de v-structure :




pas de circuit :




## 4 règles de propagation :


pas de v-structure :



ni circuit ni v-structure :




pas de circuit :




## 4 règles de propagation :


pas de v-structure :




ni circuit ni v-structure :



pas de circuit :



ni circuit ni v-structure :



$$X \text{ --- } Y = X \text{ --- } Y \text{ OU } X \rightarrow Y \text{ OU } X \leftarrow Y$$



## L'algorithme PC – Phase 2 : les propagations (2/2)

- ▶ CPDAG = completed partially directed acyclic graph  
= représentant de la classe d'équivalence de Markov

## L'algorithme PC – Phase 2 : les propagations (2/2)

- ▶ CPDAG = completed partially directed acyclic graph  
= représentant de la classe d'équivalence de Markov

Théorème – Orientation soundness – Meek(95)

- ▶ Les règles R1 à R4 sont sûres (soundness) :  
pas respectées  $\implies \exists$  nouvelle v-structure ou un circuit

## L'algorithme PC – Phase 2 : les propagations (2/2)

- ▶ CPDAG = completed partially directed acyclic graph  
= représentant de la classe d'équivalence de Markov

### Théorème – Orientation soundness – Meek(95)

- ▶ Les règles R1 à R4 sont sûres (soundness) :  
pas respectées  $\implies \exists$  nouvelle v-structure ou un circuit

### Théorème – Orientation completeness – Meek(95)

- ▶ Appliquer R1, R2, R3 sur un pattern  $\implies$  CPDAG

## L'algorithme PC – Phase 2 : les propagations (2/2)

- ▶ CPDAG = completed partially directed acyclic graph  
= représentant de la classe d'équivalence de Markov

### Théorème – Orientation soundness – Meek(95)

- ▶ Les règles R1 à R4 sont sûres (soundness) :  
pas respectées  $\implies \exists$  nouvelle v-structure ou un circuit

### Théorème – Orientation completeness – Meek(95)

- ▶ Appliquer R1, R2, R3 sur un pattern  $\implies$  CPDAG

### Théorème – Completeness with background knowledge – Meek(95)

- ▶ Background knowledge  $\mathcal{K}$  : ensemble d'arcs interdits +  
ensemble d'arcs obligatoires
- ▶ Appliquer R1 à R4 sur un pattern et orienter les arêtes  
selon  $\mathcal{K} \implies$  CPDAG

## Orientation des arêtes

- 1 // Orientation des *v*-structures
- 2  $\mathcal{G}_{PDAG} \leftarrow \mathcal{G}$
- 3 **pour chaque** *unshielded triple*  $\langle X, Z, Y \rangle$  de  $\mathcal{G}$  **faire**
- 4     **si**  $Z \notin \text{SepSet}_{XY}$  **alors**
- 5         **R0** : dans  $\mathcal{G}_{PDAG}$ , remplacer  $X - Z$  et  $Z - Y$  par  $X \rightarrow Z$  et  $Z \leftarrow Y$

## Orientation des arêtes


```
1 // Orientation des v-structures
2  $\mathcal{G}_{PDAG} \leftarrow \mathcal{G}$ 
3 pour chaque unshielded triple  $\langle X, Z, Y \rangle$  de  $\mathcal{G}$  faire
4   | si  $Z \notin \text{SepSet}_{XY}$  alors
5   | | R0 : dans  $\mathcal{G}_{PDAG}$ , remplacer  $X - Z$  et  $Z - Y$  par  $X \rightarrow Z$  et  $Z \leftarrow Y$ 
6 // Propagations
7 répéter
8   | pour chaque arête  $X - Y \in \mathcal{G}_{PDAG}$  faire
9   | | si  $(X - Y)$  arête rouge d'une règle  $R1, R2, R3$  ou  $R4$  alors
10  | | | Orienter l'arête selon la règle
11 jusqu'à ce que plus aucune arête ne puisse être orientée;
```

# Exemple d'application (1/2)


- 1 pour chaque *unshielded triple*  $\langle X, Z, Y \rangle$  de  $\mathcal{G}$  faire
- 2 si  $Z \notin \text{SepSet}_{XY}$  alors
- 3  $\left[ \begin{array}{l} \text{R0 : dans } \mathcal{G}_{PDAG}, \text{ remplacer } X - Z \text{ et } Z - Y \text{ par } X \rightarrow Z \text{ et } Z \leftarrow Y \end{array} \right.$

Sepsets :

- ▶  $S_{AB} = S_{AL} = S_{AS} = \emptyset$        $S_{AD} = S_{AO} = S_{AX} = \{T\}$
- ▶  $S_{BT} = \emptyset$        $S_{BL} = S_{BO} = S_{BX} = \{S\}$
- ▶  $S_{DL} = S_{DS} = \{O, B\}$        $S_{DT} = \{O, S\}$        $S_{DX} = \{O\}$
- ▶  $S_{LT} = \emptyset$        $S_{LX} = \{O\}$        $S_{OS} = \{L\}$
- ▶  $S_{ST} = \emptyset$        $S_{SX} = \{L\}$        $S_{TX} = \{O\}$




Après phase 1




Après R0

## Exemple d'application (2/2)

- 1 // Propagation sans rajouter de v-structure
- 2 **pour chaque** arête  $(X, Y) \in \mathcal{G}_{PDAG}$  **faire**
- 3     **si**  $(X - Y)$  arête rouge de  $R1$  ( $Z \rightarrow X$  et  $X - Y$ ) **alors**
- 4     |     remplacer  $X - Y$  par  $X \rightarrow Y$



Après  $R0$




Après  $R1$




## Exemple d'application (2/2)

- 1 // Propagation sans rajouter de v-structure
- 2 **pour chaque** arête  $(X, Y) \in \mathcal{G}_{PDAG}$  **faire**
- 3     **si**  $(X - Y)$  arête rouge de  $R1$  ( $Z \rightarrow X$  et  $X - Y$ ) **alors**
- 4     |     remplacer  $X - Y$  par  $X \rightarrow Y$



Après  $R0$




Après  $R1$

Résultat : représentant de la classe d'équivalence de Markov


► CPDAG : completed partially directed acyclic graph

# Phase 3 : compléter les orientations sans créer de v-structure


6 possibilités :




Après  $R1$



1ère possibilité



2ème possibilité



3ème possibilité

► 3 autres possibilités similaires mais avec  $T \rightarrow A$

## Tests d'indépendance conditionnelle (1/2)

- ▶  $X, Y$  : 2 variables aléatoires,  $\mathbf{Z}$  : ensemble de variables
- ▶  $N_{xyz}$  : nombre d'occurrences de  $(X = x, Y = y, \mathbf{Z} = \mathbf{z})$  dans  $\mathbf{D}$

# Tests d'indépendance conditionnelle (1/2)

- ▶  $X, Y$  : 2 variables aléatoires,  $\mathbf{Z}$  : ensemble de variables
- ▶  $N_{xyz}$  : nombre d'occurrences de  $(X = x, Y = y, \mathbf{Z} = \mathbf{z})$  dans  $\mathbf{D}$
- ▶  $N_{xz} = \sum_{y \in \Omega_Y} N_{xyz}$        $N_{yz} = \sum_{x \in \Omega_X} N_{xyz}$        $N_{\mathbf{z}} = \sum_{x \in \Omega_X} N_{xz}$

## Test du $\chi^2$

$$\chi^2_{\text{statistics}}(X, Y | \mathbf{Z}) = \sum_{x \in \Omega_X} \sum_{y \in \Omega_Y} \sum_{\mathbf{z} \in \Omega_{\mathbf{Z}}} \frac{\left( N_{xyz} - \frac{N_{xz} N_{yz}}{N_{\mathbf{z}}} \right)^2}{\frac{N_{xz} N_{yz}}{N_{\mathbf{z}}}}$$

# Tests d'indépendance conditionnelle (1/2)

- ▶  $X, Y$  : 2 variables aléatoires,  $\mathbf{Z}$  : ensemble de variables
- ▶  $N_{xyz}$  : nombre d'occurrences de  $(X = x, Y = y, \mathbf{Z} = \mathbf{z})$  dans  $\mathbf{D}$
- ▶  $N_{xz} = \sum_{y \in \Omega_Y} N_{xyz}$      $N_{yz} = \sum_{x \in \Omega_X} N_{xyz}$      $N_{\mathbf{z}} = \sum_{x \in \Omega_X} N_{xz}$

## Test du $\chi^2$

$$\chi_{\text{statistics}}^2(X, Y|\mathbf{Z}) = \sum_{x \in \Omega_X} \sum_{y \in \Omega_Y} \sum_{\mathbf{z} \in \Omega_{\mathbf{Z}}} \frac{\left( N_{xyz} - \frac{N_{xz} N_{yz}}{N_{\mathbf{z}}} \right)^2}{\frac{N_{xz} N_{yz}}{N_{\mathbf{z}}}}$$

- ▶ Nb degrés de liberté :  $df = (|\Omega_X| - 1) \times (|\Omega_Y| - 1) \times |\Omega_{\mathbf{Z}}|$
- ▶  $\alpha$  : niveau de risque (souvent 5%)
- ▶ Si  $\chi_{\text{statistics}}^2(X, Y|\mathbf{Z}) \leq \chi^2(df, \alpha)$  alors  $X \perp\!\!\!\perp Y|\mathbf{Z}$



Règle usuelle : ne faire le test que si  $N_{xyz} \geq 5$  pour tout  $x, y, \mathbf{z}$

## Test du $G^2$

$$G^2_{\text{statistics}}(X, Y|Z) = 2 \sum_{x \in \Omega_X} \sum_{y \in \Omega_Y} \sum_{z \in \Omega_Z} N_{xyz} \ln \frac{N_{xyz} N_z}{N_{xz} N_{yz}}$$

## Test du $G^2$

$$G_{statistics}^2(X, Y|Z) = 2 \sum_{x \in \Omega_X} \sum_{y \in \Omega_Y} \sum_{z \in \Omega_Z} N_{xyz} \ln \frac{N_{xyz} N_z}{N_{xz} N_{yz}}$$

- ▶ Nb degrés de liberté :  $df = (|\Omega_X| - 1) \times (|\Omega_Y| - 1) \times |\Omega_Z|$
- ▶  $\alpha$  : niveau de risque (e.g. 5%)
- ▶ Si  $G_{statistics}^2(X, Y|Z) \leq \chi^2(df, \alpha)$  alors  $X \perp\!\!\!\perp Y|Z$
- ▶ En pratique, tests du  $G^2$  plus robustes que ceux du  $\chi^2$

► Résultat dépendant de l'ordre des calculs :

- 1 **pour chaque** arête  $X - Y$  t.q.  $|\text{Adj}(X) \setminus \{Y\}| \geq d$  **faire**
- 2     ...
- 3     Supprimer l'arête  $X - Y$  de  $\mathcal{G}$
- 4     ...



► Résultat dépendant de l'ordre des calculs :

- 1 **pour chaque** arête  $X - Y$  t.q.  $|\text{Adj}(X) \setminus \{Y\}| \geq d$  **faire**
- 2     ...
- 3     Supprimer l'arête  $X - Y$  de  $\mathcal{G}$
- 4     ...

⇒ PC-stable, variante de [Colombo et Maathuis \(2014\)](#)

- ▶ Résultat dépendant de l'ordre des calculs :

- 1 **pour chaque** arête  $X - Y$  t.q.  $|\text{Adj}(X) \setminus \{Y\}| \geq d$  **faire**
- 2     ...
- 3     Supprimer l'arête  $X - Y$  de  $\mathcal{G}$
- 4     ...

⇒ PC-stable, variante de [Colombo et Maathuis \(2014\)](#)

- ▶  $|\mathbf{D}|$  petite ⇒ tests  $\chi^2$  et  $G^2$  peu fiables

# Problèmes de l'algorithme PC


- ▶ Résultat dépendant de l'ordre des calculs :

- 1 **pour chaque** arête  $X - Y$  t.q.  $|\text{Adj}(X) \setminus \{Y\}| \geq d$  **faire**
- 2     ...
- 3     Supprimer l'arête  $X - Y$  de  $\mathcal{G}$
- 4     ...

⇒ PC-stable, variante de [Colombo et Maathuis \(2014\)](#)

- ▶  $|D|$  petite ⇒ tests  $\chi^2$  et  $G^2$  peu fiables

- ▶ Phase 3 : pas d'orientation possible :



# Problèmes de l'algorithme PC


- ▶ Résultat dépendant de l'ordre des calculs :

```
1 pour chaque arête  $X - Y$  t.q.  $|\text{Adj}(X) \setminus \{Y\}| \geq d$  faire  
2   ...  
3   Supprimer l'arête  $X - Y$  de  $\mathcal{G}$   
4   ...
```

⇒ PC-stable, variante de [Colombo et Maathuis \(2014\)](#)

- ▶  $|\mathbf{D}|$  petite ⇒ tests  $\chi^2$  et  $G^2$  peu fiables

- ▶ Phase 3 : pas d'orientation possible :



- ▶ cause 1 : pas de DAG-faithfulness (relations déterministes ?)  
[Luo \(2006\)](#), [Rodrigues de Morais et al. \(2008\)](#), [Mabrouk et al. \(2014\)](#)


- ▶ Résultat dépendant de l'ordre des calculs :

```
1 pour chaque arête  $X - Y$  t.q.  $|\text{Adj}(X) \setminus \{Y\}| \geq d$  faire  
2   ...  
3   Supprimer l'arête  $X - Y$  de  $\mathcal{G}$   
4   ...
```

⇒ PC-stable, variante de [Colombo et Maathuis \(2014\)](#)

- ▶  $|\mathbf{D}|$  petite ⇒ tests  $\chi^2$  et  $G^2$  peu fiables

- ▶ Phase 3 : pas d'orientation possible :




- ▶ cause 1 : pas de DAG-faithfulness (relations déterministes ?)  
[Luo \(2006\)](#), [Rodrigues de Morais et al. \(2008\)](#), [Mabrouk et al. \(2014\)](#)
- ▶ cause 2 : erreurs dans les tests statistiques

- ▶ Résultat dépendant de l'ordre des calculs :

```
1 pour chaque arête  $X - Y$  t.q.  $|\text{Adj}(X) \setminus \{Y\}| \geq d$  faire  
2   ...  
3   Supprimer l'arête  $X - Y$  de  $\mathcal{G}$   
4   ...
```

⇒ PC-stable, variante de [Colombo et Maathuis \(2014\)](#)

- ▶  $|\mathbf{D}|$  petite ⇒ tests  $\chi^2$  et  $G^2$  peu fiables
- ▶ Phase 3 : pas d'orientation possible :



- ▶ cause 1 : pas de DAG-faithfulness (relations déterministes ?)  
[Luo \(2006\)](#), [Rodrigues de Morais et al. \(2008\)](#), [Mabrouk et al. \(2014\)](#)
- ▶ cause 2 : erreurs dans les tests statistiques
- ▶ cause 3 : présence de variables latentes (non observées)  
⇒ IC\* [Verma \(1993\)](#), FCI [Spirtes, Glymour et Scheines \(2000\)](#)

## ② Apprentissage à base de scores



Meilleure structure : celle qui colle le mieux aux données





Meilleure structure : celle qui colle le mieux aux données

$\implies$  1 vraisemblance :  $\mathcal{G}^* = \text{Argmax}_{\mathcal{G}} \mathcal{L}(\mathcal{G} : \mathbf{D})$



Meilleure structure : celle qui colle le mieux aux données

⇒ 1 vraisemblance :  $\mathcal{G}^* = \text{Argmax}_{\mathcal{G}} \mathcal{L}(\mathcal{G} : \mathbf{D})$

2  $\mathcal{G}^* =$  structure choisie avec le moins de « regret »



Meilleure structure : celle qui colle le mieux aux données

⇒ 1 vraisemblance :  $\mathcal{G}^* = \text{Argmax}_{\mathcal{G}} \mathcal{L}(\mathcal{G} : \mathbf{D})$

2  $\mathcal{G}^* =$  structure choisie avec le moins de « regret »

⇒ différents scores



Meilleure structure : celle qui colle le mieux aux données

⇒ ① vraisemblance :  $\mathcal{G}^* = \text{Argmax}_{\mathcal{G}} \mathcal{L}(\mathcal{G} : \mathbf{D})$

②  $\mathcal{G}^* =$  structure choisie avec le moins de « regret »

⇒ différents scores

## *Propriétés souhaitables des scores*

### ► **Rasoir d'Occam :**

Privilégier les  $\mathcal{G}$  simples plutôt que complexes



Meilleure structure : celle qui colle le mieux aux données

⇒ ① vraisemblance :  $\mathcal{G}^* = \text{Argmax}_{\mathcal{G}} \mathcal{L}(\mathcal{G} : \mathbf{D})$

②  $\mathcal{G}^* =$  structure choisie avec le moins de « regret »

⇒ différents scores

## *Propriétés souhaitables des scores*

### ▶ **Rasoir d'Occam :**

Privilégier les  $\mathcal{G}$  simples plutôt que complexes

### ▶ **Consistance locale :**

Ajouter un arc « utile » devrait augmenter le score

Ajouter un arc « inutile » devrait diminuer le score



Meilleure structure : celle qui colle le mieux aux données

⇒ ① vraisemblance :  $\mathcal{G}^* = \text{Argmax}_{\mathcal{G}} \mathcal{L}(\mathcal{G} : \mathbf{D})$

②  $\mathcal{G}^*$  = structure choisie avec le moins de « regret »

⇒ différents scores

## *Propriétés souhaitables des scores*

### ▶ **Rasoir d'Occam :**

Privilégier les  $\mathcal{G}$  simples plutôt que complexes

### ▶ **Consistance locale :**

Ajouter un arc « utile » devrait augmenter le score

Ajouter un arc « inutile » devrait diminuer le score

### ▶ **Score équivalence :**

2 RB Markov-équivalents devraient avoir le même score



Meilleure structure : celle qui colle le mieux aux données

⇒ ① vraisemblance :  $\mathcal{G}^* = \text{Argmax}_{\mathcal{G}} \mathcal{L}(\mathcal{G} : \mathbf{D})$

②  $\mathcal{G}^*$  = structure choisie avec le moins de « regret »

⇒ différents scores

## *Propriétés souhaitables des scores*

### ▶ **Rasoir d'Occam :**

Privilégier les  $\mathcal{G}$  simples plutôt que complexes

### ▶ **Consistance locale :**

Ajouter un arc « utile » devrait augmenter le score

Ajouter un arc « inutile » devrait diminuer le score

### ▶ **Score équivalence :**

2 RB Markov-équivalents devraient avoir le même score

### ▶ **Décomposition locale :**

L'ajout/retrait d'un arc  $\implies$  score mis à jour en ne regardant que la partie de  $\mathcal{G}$  autour de l'arc

## *Voisinage d'un DAG $\mathcal{G}$*

Voisinage de  $\mathcal{G}$  = ensemble des graphes  $\mathcal{G}'$  t.q. :

- ▶  $\mathcal{G}'$  est un DAG
- ▶  $\mathcal{G}'$  s'obtient en appliquant à  $\mathcal{G}$  **un** opérateur parmi :
  - ▶ l'ajout d'un arc
  - ▶ la suppression d'un arc
  - ▶ le retournement d'un arc

On note  $\mathcal{N}(\mathcal{G})$  le voisinage de  $\mathcal{G}$



## Voisinage d'un DAG $\mathcal{G}$

Voisinage de  $\mathcal{G}$  = ensemble des graphes  $\mathcal{G}'$  t.q. :

- ▶  $\mathcal{G}'$  est un DAG
- ▶  $\mathcal{G}'$  s'obtient en appliquant à  $\mathcal{G}$  un opérateur parmi :
  - ▶ l'ajout d'un arc
  - ▶ la suppression d'un arc
  - ▶ le retournement d'un arc

On note  $\mathcal{N}(\mathcal{G})$  le voisinage de  $\mathcal{G}$



- 1 Parcourir l'espace des DAG en partant d'un graphe  $\mathcal{G}_0$

## Voisinage d'un DAG $\mathcal{G}$

Voisinage de  $\mathcal{G}$  = ensemble des graphes  $\mathcal{G}'$  t.q. :

- ▶  $\mathcal{G}'$  est un DAG
- ▶  $\mathcal{G}'$  s'obtient en appliquant à  $\mathcal{G}$  **un** opérateur parmi :
  - ▶ l'ajout d'un arc
  - ▶ la suppression d'un arc
  - ▶ le retournement d'un arc

On note  $\mathcal{N}(\mathcal{G})$  le voisinage de  $\mathcal{G}$



- 1 Parcourir l'espace des DAG en partant d'un graphe  $\mathcal{G}_0$
- 2 en trouvant dans son voisinage le graphe  $\mathcal{G}'$  de score plus élevé

## Voisinage d'un DAG $\mathcal{G}$

Voisinage de  $\mathcal{G}$  = ensemble des graphes  $\mathcal{G}'$  t.q. :

- ▶  $\mathcal{G}'$  est un DAG
- ▶  $\mathcal{G}'$  s'obtient en appliquant à  $\mathcal{G}$  un opérateur parmi :
  - ▶ l'ajout d'un arc
  - ▶ la suppression d'un arc
  - ▶ le retournement d'un arc

On note  $\mathcal{N}(\mathcal{G})$  le voisinage de  $\mathcal{G}$



- 1 Parcourir l'espace des DAG en partant d'un graphe  $\mathcal{G}_0$
- 2 en trouvant dans son voisinage le graphe  $\mathcal{G}'$  de score plus élevé
- 3 en itérant le processus avec  $\mathcal{G}'$  jusqu'à un optimum (local)

## Voisinage d'un DAG $\mathcal{G}$

Voisinage de  $\mathcal{G}$  = ensemble des graphes  $\mathcal{G}'$  t.q. :

- ▶  $\mathcal{G}'$  est un DAG
- ▶  $\mathcal{G}'$  s'obtient en appliquant à  $\mathcal{G}$  un opérateur parmi :
  - ▶ l'ajout d'un arc
  - ▶ la suppression d'un arc
  - ▶ le retournement d'un arc

On note  $\mathcal{N}(\mathcal{G})$  le voisinage de  $\mathcal{G}$



- 1 Parcourir l'espace des DAG en partant d'un graphe  $\mathcal{G}_0$
- 2 en trouvant dans son voisinage le graphe  $\mathcal{G}'$  de score plus élevé
- 3 en itérant le processus avec  $\mathcal{G}'$  jusqu'à un optimum (local)

⇒ Algorithme « Greedy Hill Climbing »

## Algorithme d'apprentissage « glouton » :

```
1 // étape ①
2  $\mathcal{G}_{best} \leftarrow$  graphe orienté vide (sans arc) // meilleur graphe trouvé
3  $sc_{best} \leftarrow \text{Score}(\mathcal{G}_{best})$  // score du meilleur DAG
4
5 // parcours de l'espace des DAG – étape ③
6 répéter
7   // recherche du meilleur voisin
8    $\mathcal{N} \leftarrow$  voisinage de  $\mathcal{G}_{best}$  // calcul du voisinage
9   trouvé  $\leftarrow$  false // meilleur voisin pas encore trouvé
10  // parcours du voisinage – étape ②
11  pour chaque  $\mathcal{G}' \in \mathcal{N}$  faire
12     $sc' \leftarrow \text{Score}(\mathcal{G}')$ 
13    si  $sc' > sc_{best}$  alors
14       $\mathcal{G}_{best} \leftarrow \mathcal{G}'$ ,  $sc_{best} \leftarrow sc'$ 
15      trouvé  $\leftarrow$  true
16 jusqu'à trouvé = false;
17 Retourner  $\mathcal{G}_{best}$  // graphe localement optimal
```

# Exemple d'application



▶ Étape ① :  $\mathcal{G}_{best} = \textcircled{A}$      $\textcircled{B}$      $\textcircled{C}$      $SC_{best} = 0$

# Exemple d'application

▶ Étape 1 :  $\mathcal{G}_{best} =$      $SC_{best} = 0$

---

▶ Voisinage  $\mathcal{N}$  :




# Exemple d'application

▶ Étape 1 :  $\mathcal{G}_{best} =$    $SC_{best} = 0$

---

▶ Voisinage  $\mathcal{N}$  :



▶ Nouveau graphe  $\mathcal{G}_{best} =$    $SC_{best} = 3$




# Exemple d'application

▶ Étape 1 :  $\mathcal{G}_{best} = \textcircled{A} \quad \textcircled{B} \quad \textcircled{C} \quad SC_{best} = 0$

---


▶ Voisinage  $\mathcal{N}$  :



▶ Nouveau graphe  $\mathcal{G}_{best} = \textcircled{A} \leftarrow \textcircled{B} \quad \textcircled{C} \quad SC_{best} = 3$

---


▶ Nouveau voisinage  $\mathcal{N}$  :



# Exemple d'application


▶ Étape 1 :  $\mathcal{G}_{best} =$    $SC_{best} = 0$

▶ Voisinage  $\mathcal{N}$  :



▶ Nouveau graphe  $\mathcal{G}_{best} =$     $SC_{best} = 3$

▶ Nouveau voisinage  $\mathcal{N}$  :




▶ Nouveau graphe  $\mathcal{G}_{best} =$    $SC_{best} = 4$

# Exemple d'application


▶ Étape 1 :  $\mathcal{G}_{best} = \textcircled{A} \quad \textcircled{B} \quad \textcircled{C} \quad SC_{best} = 0$

▶ Voisinage  $\mathcal{N}$  :



▶ Nouveau graphe  $\mathcal{G}_{best} = \textcircled{A} \leftarrow \textcircled{B} \quad \textcircled{C} \quad SC_{best} = 3$

▶ Nouveau voisinage  $\mathcal{N}$  :



▶ Nouveau graphe  $\mathcal{G}_{best} = \textcircled{A} \leftarrow \textcircled{B} \rightarrow \textcircled{C} \quad SC_{best} = 4$

▶ Nouveau voisinage  $\mathcal{N}$  :

.....

Score  $BD(\mathcal{G}|\mathbf{D})$

[Heckerman, Geiger and Chickering (1995)]

$$\text{Score}_{BD}(\mathcal{G}|\mathbf{D}) = \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(N_{ij} + \alpha_{ij})} \prod_{k=1}^{r_i} \frac{\Gamma(N_{ijk} + \alpha_{ijk})}{\Gamma(\alpha_{ijk})}$$

►  $\Gamma(\cdot)$  : généralisation continue de la factorielle

$\Gamma(n) = (n - 1)!$  pour tout  $n \in \mathbb{N}^*$

Score  $BD(\mathcal{G}|\mathbf{D})$  [Heckerman, Geiger and Chickering (1995)]

$$\text{Score}_{BD}(\mathcal{G}|\mathbf{D}) = \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(N_{ij} + \alpha_{ij})} \prod_{k=1}^{r_i} \frac{\Gamma(N_{ijk} + \alpha_{ijk})}{\Gamma(\alpha_{ijk})}$$

►  $\Gamma(\cdot)$  : généralisation continue de la factorielle

$$\Gamma(n) = (n - 1)! \text{ pour tout } n \in \mathbb{N}^*$$

►  $\text{Score}_{BD}(X_i|\mathbf{Pa}(X_i), \mathbf{D}) = \prod_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(N_{ij} + \alpha_{ij})} \prod_{k=1}^{r_i} \frac{\Gamma(N_{ijk} + \alpha_{ijk})}{\Gamma(\alpha_{ijk})}$

►  $\text{Score}_{BD}(\mathcal{G}|\mathbf{D}) = \prod_{i=1}^n \text{Score}_{BD}(X_i|\mathbf{Pa}(X_i), \mathbf{D})$



En pratique, on calcule plutôt  $\log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$



En pratique, on calcule plutôt  $\log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$

*Score*  $BD(\mathcal{G}|\mathbf{D})$  [Heckerman, Geiger and Chickering (1995)]

►  $\log(\text{Score}_{BD}(X_i|\mathbf{Pa}(X_i), \mathbf{D}))$

$$= \sum_{j=1}^{q_i} \log \Gamma(\alpha_{ij}) - \log \Gamma(N_{ij} + \alpha_{ij}) + \sum_{k=1}^{r_i} \log \Gamma(N_{ijk} + \alpha_{ijk}) - \log \Gamma(\alpha_{ijk})$$

►  $\log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D})) = \sum_{i=1}^n \log(\text{Score}_{BD}(X_i|\mathbf{Pa}(X_i), \mathbf{D}))$

Score K2

[Cooper et Herskovits (1992)]

►  $\text{Score}_{K2}(\mathcal{G}|\mathbf{D}) = \log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$  avec :

$\alpha_{ijk} = 1$  pour tout  $i, j, k$



## Score K2

[Cooper et Herskovits (1992)]

►  $\text{Score}_{K2}(\mathcal{G}|\mathbf{D}) = \log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$  avec :

$\alpha_{ijk} = 1$  pour tout  $i, j, k$

⇒ revient à rajouter 1 dans chaque cellule des tableaux de contingence (de comptage)

## Score K2

[Cooper et Herskovits (1992)]

►  $\text{Score}_{K2}(\mathcal{G}|\mathbf{D}) = \log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$  avec :

$\alpha_{ijk} = 1$  pour tout  $i, j, k$

⇒ revient à rajouter 1 dans chaque cellule des tableaux de contingence (de comptage)

⇒ revient à rajouter  $r_i q_i$  observations dans  $\mathbf{D}$

## Score K2

[Cooper et Herskovits (1992)]

►  $\text{Score}_{K2}(\mathcal{G}|\mathbf{D}) = \log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$  avec :

$\alpha_{ijk} = 1$  pour tout  $i, j, k$

⇒ revient à rajouter 1 dans chaque cellule des tableaux de contingence (de comptage)

⇒ revient à rajouter  $r_i q_i$  observations dans  $\mathbf{D}$

►  $\text{Score}_{K2}(X_i|\mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$

►  $\text{Score}_{K2}(\mathcal{G}|\mathbf{D}) = \sum_{i=1}^n \text{Score}_{K2}(X_i|\mathbf{Pa}(X_i), \mathbf{D})$

## Exemple d'application (1/2)

$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$

## Exemple d'application (1/2)

$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$

A

B

C

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

## Exemple d'application (1/2)

$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$

A

B

C

►  $\mathbf{D} \implies r_i = 2$  pour tout  $i$  ( $|\Omega_A| = |\Omega_B| = |\Omega_C| = 2$ )

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

## Exemple d'application (1/2)

$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$

A

B

C

►  $\mathbf{D} \implies r_i = 2$  pour tout  $i$  ( $|\Omega_A| = |\Omega_B| = |\Omega_C| = 2$ )

►  $\mathcal{G} \implies q_i = 1$  (pas de parent) et  $N_{ij} = |\mathbf{D}| = 7 \forall i$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (1/2)

$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$

**A**

**B**

**C**

►  $\mathbf{D} \implies r_i = 2$  pour tout  $i$  ( $|\Omega_A| = |\Omega_B| = |\Omega_C| = 2$ )

►  $\mathcal{G} \implies q_i = 1$  (pas de parent) et  $N_{ij} = |\mathbf{D}| = 7 \forall i$

►  $i = 1$  (A) :

$a_1$	$a_2$
3	4

$r_1 = |\Omega_A| = 2$   
 $\mathbf{Pa}(A) = \emptyset \implies q_i = 1$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$



# Exemple d'application (1/2)

$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$

**A**

**B**

**C**

►  $\mathbf{D} \implies r_i = 2$  pour tout  $i$  ( $|\Omega_A| = |\Omega_B| = |\Omega_C| = 2$ )

►  $\mathcal{G} \implies q_i = 1$  (pas de parent) et  $N_{ij} = |\mathbf{D}| = 7 \forall i$

►  $i = 1$  (A) : 

$a_1$	$a_2$
3	4

 $r_1 = |\Omega_A| = 2$   
 $\mathbf{Pa}(A) = \emptyset \implies q_i = 1$

$$\text{Score}_{K2}(A) = \log \left( \frac{(2-1)!}{(7+2-1)!} \right) + \log(3!) + \log(4!) \approx -5,6348$$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (1/2)

$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$

**A**

**B**

**C**

►  $\mathbf{D} \implies r_i = 2$  pour tout  $i$  ( $|\Omega_A| = |\Omega_B| = |\Omega_C| = 2$ )

►  $\mathcal{G} \implies q_i = 1$  (pas de parent) et  $N_{ij} = |\mathbf{D}| = 7 \forall i$

►  $i = 1$  (A) : 

$a_1$	$a_2$
3	4

 $r_1 = |\Omega_A| = 2$   
 $\mathbf{Pa}(A) = \emptyset \implies q_1 = 1$

$$\text{Score}_{K2}(A) = \log \left( \frac{(2-1)!}{(7+2-1)!} \right) + \log(3!) + \log(4!) \approx -5,6348$$

►  $i = 2$  (B) : 

$b_1$	$b_2$
3	4

 $\text{Score}_{K2}(B) \approx -5,6348$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (1/2)

$$\text{Score}_{K_2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$

**A**

**B**

**C**

►  $\mathbf{D} \implies r_i = 2$  pour tout  $i$  ( $|\Omega_A| = |\Omega_B| = |\Omega_C| = 2$ )

►  $\mathcal{G} \implies q_i = 1$  (pas de parent) et  $N_{ij} = |\mathbf{D}| = 7 \forall i$

►  $i = 1$  (A) : 

$a_1$	$a_2$
3	4

 $r_1 = |\Omega_A| = 2$   
 $\mathbf{Pa}(A) = \emptyset \implies q_1 = 1$

$$\text{Score}_{K_2}(A) = \log \left( \frac{(2-1)!}{(7+2-1)!} \right) + \log(3!) + \log(4!) \approx -5,6348$$

►  $i = 2$  (B) : 

$b_1$	$b_2$
3	4

 $\text{Score}_{K_2}(B) \approx -5,6348$

►  $i = 3$  (C) : 

$c_1$	$c_2$
4	3

 $\text{Score}_{K_2}(C) \approx -5,6348$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (1/2)

$$\text{Score}_{K_2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$

**A**

**B**

**C**

►  $\mathbf{D} \implies r_i = 2$  pour tout  $i$  ( $|\Omega_A| = |\Omega_B| = |\Omega_C| = 2$ )

►  $\mathcal{G} \implies q_i = 1$  (pas de parent) et  $N_{ij} = |\mathbf{D}| = 7 \forall i$

►  $i = 1$  (A) : 

$a_1$	$a_2$
3	4

 $r_1 = |\Omega_A| = 2$   
 $\mathbf{Pa}(A) = \emptyset \implies q_1 = 1$

$$\text{Score}_{K_2}(A) = \log \left( \frac{(2-1)!}{(7+2-1)!} \right) + \log(3!) + \log(4!) \approx -5,6348$$

►  $i = 2$  (B) : 

$b_1$	$b_2$
3	4

 $\text{Score}_{K_2}(B) \approx -5,6348$

►  $i = 3$  (C) : 

$c_1$	$c_2$
4	3


 $\text{Score}_{K_2}(C) \approx -5,6348$

►  $\text{Score}_{K_2}(\mathcal{G}) \approx -5,6348 - 5,6348 - 5,6348 = -16,9044$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

## Exemple d'application (2/2)


$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$



A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (2/2)

$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$



►  $\text{Score}_{K2}(B)$  et  $\text{Score}_{K2}(C)$  inchangés  $\approx -5,6348$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$


►  $(A|B)$  :

	$a_1$	$a_2$	$N_{ij}$
$b_1$	2	1	3
$b_2$	1	3	4

$N_{ij} = \sum$  sur chaque ligne

# Exemple d'application (2/2)

$$\text{Score}_{K2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$



►  $\text{Score}_{K2}(B)$  et  $\text{Score}_{K2}(C)$  inchangés  $\approx -5,6348$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

►  $(A|B)$  :


	$a_1$	$a_2$	$N_{ij}$
$b_1$	2	1	3
$b_2$	1	3	4

$N_{ij} = \sum$  sur chaque ligne

$$\begin{aligned} \text{Score}_{K2}(A|B) &= \log \left( \frac{(2-1)!}{(3+2-1)!} \right) + \log(2!) + \log(1!) \quad (\text{ligne } b_1) \\ &+ \log \left( \frac{(2-1)!}{(4+2-1)!} \right) + \log(1!) + \log(3!) \quad (\text{ligne } b_2) \\ &\approx -6,1738 \end{aligned}$$

# Exemple d'application (2/2)

$$\text{Score}_{K_2}(X_i | \mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \left[ \log \left( \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \right) + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right]$$



- $\text{Score}_{K_2}(B)$  et  $\text{Score}_{K_2}(C)$  inchangés  $\approx -5,6348$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

- $(A|B)$  : 

	$a_1$	$a_2$	$N_{ij}$
$b_1$	2	1	3
$b_2$	1	3	4

 $N_{ij} = \sum$  sur chaque ligne

$$\begin{aligned} \text{Score}_{K_2}(A|B) &= \log \left( \frac{(2-1)!}{(3+2-1)!} \right) + \log(2!) + \log(1!) \quad (\text{ligne } b_1) \\ &\quad + \log \left( \frac{(2-1)!}{(4+2-1)!} \right) + \log(1!) + \log(3!) \quad (\text{ligne } b_2) \\ &\approx -6,1738 \end{aligned}$$

- $\text{Score}_{K_2}(\mathcal{G}) \approx -6,1738 - 5,6348 - 5,6348 = -17,4434$   
 $\implies$  Graphe moins probable que celui du slide précédent



- ▶ **Problème** : Score K2 non score-équivalent :  
2 RB Markov-équivalents n'ont pas forcément le même score !

## Score BDeu

[Buntine (1991)]

- ▶  $\text{Score}_{BDeu}(\mathcal{G}|\mathbf{D}) = \log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$  avec :

$$\alpha_{ijk} = \frac{N'}{r_i q_i} \text{ pour tout } i, j, k \quad N' = \ll \text{effective sample size} \gg$$

⇒ revient à rajouter  $\frac{N'}{r_i q_i}$  dans chaque cellule des tableaux de contingence (de comptage)

- ▶ **Problème** : Score K2 non score-équivalent :  
2 RB Markov-équivalents n'ont pas forcément le même score !

## Score BDeu

[Buntine (1991)]

- ▶  $\text{Score}_{BDeu}(\mathcal{G}|\mathbf{D}) = \log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$  avec :

$$\alpha_{ijk} = \frac{N'}{r_i q_i} \text{ pour tout } i, j, k \quad N' = \ll \text{effective sample size} \gg$$

⇒ revient à rajouter  $\frac{N'}{r_i q_i}$  dans chaque cellule des tableaux de contingence (de comptage)

⇒ revient à rajouter  $N'$  observations dans  $\mathbf{D}$

- ▶ **Problème** : Score K2 non score-équivalent :  
2 RB Markov-équivalents n'ont pas forcément le même score !

## Score BDeu

[Buntine (1991)]

- ▶  $\text{Score}_{BDeu}(\mathcal{G}|\mathbf{D}) = \log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$  avec :

$$\alpha_{ijk} = \frac{N'}{r_i q_i} \text{ pour tout } i, j, k \quad N' = \ll \text{effective sample size} \gg$$

⇒ revient à rajouter  $\frac{N'}{r_i q_i}$  dans chaque cellule des tableaux de contingence (de comptage)

⇒ revient à rajouter  $N'$  observations dans  $\mathbf{D}$

- ▶  $\text{Score}_{BDeu}(X_i | \mathbf{Pa}(X_i), \mathbf{D})$

$$= \sum_{j=1}^{q_i} \log \Gamma \left( \frac{N'}{q_i} \right) - \log \Gamma \left( N_{ij} + \frac{N'}{q_i} \right) + \sum_{k=1}^{r_i} \log \Gamma \left( N_{ijk} + \frac{N'}{r_i q_i} \right) - \log \Gamma \left( \frac{N'}{r_i q_i} \right)$$

- ▶  $\text{Score}_{BDeu}(\mathcal{G}|\mathbf{D}) = \sum_{i=1}^n \text{Score}_{BDeu}(X_i | \mathbf{Pa}(X_i), \mathbf{D})$

- ▶ **Problème** : Score K2 non score-équivalent :  
2 RB Markov-équivalents n'ont pas forcément le même score !

## Score BDeu

[Buntine (1991)]

- ▶  $\text{Score}_{BDeu}(\mathcal{G}|\mathbf{D}) = \log(\text{Score}_{BD}(\mathcal{G}|\mathbf{D}))$  avec :

$$\alpha_{ijk} = \frac{N'}{r_i q_i} \text{ pour tout } i, j, k \quad N' = \ll \text{effective sample size} \gg$$

⇒ revient à rajouter  $\frac{N'}{r_i q_i}$  dans chaque cellule des tableaux de contingence (de comptage)

⇒ revient à rajouter  $N'$  observations dans  $\mathbf{D}$

- ▶  $\text{Score}_{BDeu}(X_i | \mathbf{Pa}(X_i), \mathbf{D})$

$$= \sum_{j=1}^{q_i} \log \Gamma \left( \frac{N'}{q_i} \right) - \log \Gamma \left( N_{ij} + \frac{N'}{q_i} \right) + \sum_{k=1}^{r_i} \log \Gamma \left( N_{ijk} + \frac{N'}{r_i q_i} \right) - \log \Gamma \left( \frac{N'}{r_i q_i} \right)$$

- ▶  $\text{Score}_{BDeu}(\mathcal{G}|\mathbf{D}) = \sum_{i=1}^n \text{Score}_{BDeu}(X_i | \mathbf{Pa}(X_i), \mathbf{D})$

- ▶ BDeu : score équivalent [Heckerman, Geiger, Chickering (1995)]

► Score BD( $\mathcal{G}$ ) :  $\int_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)\pi(\Theta|\mathcal{G})d\Theta$

► Score  $BD(\mathcal{G}) : \int_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)\pi(\Theta|\mathcal{G})d\Theta$

⇒ vraisemblance moyenne sur {RB de structure  $\mathcal{G}$ }

⇒ moyenne sur tous les paramètres

- ▶ Score BD( $\mathcal{G}$ ) :  $\int_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)\pi(\Theta|\mathcal{G})d\Theta$ 
  - ⇒ vraisemblance moyenne sur {RB de structure  $\mathcal{G}$ }
  - ⇒ moyenne sur tous les paramètres
  
- ▶ Et si on utilisait les paramètres optimaux plutôt que la moyenne ?  
Score( $\mathcal{G}$ ) :  $\max_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)$

► Score BD( $\mathcal{G}$ ) :  $\int_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)\pi(\Theta|\mathcal{G})d\Theta$

⇒ vraisemblance moyenne sur {RB de structure  $\mathcal{G}$ }

⇒ moyenne sur tous les paramètres

► Et si on utilisait les paramètres optimaux plutôt que la moyenne ?

Score( $\mathcal{G}$ ) :  $\max_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)$

⇒ Paramètres qui « collent » le plus aux données



- ▶ Score  $BD(\mathcal{G}) : \int_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)\pi(\Theta|\mathcal{G})d\Theta$ 
  - ⇒ vraisemblance moyenne sur {RB de structure  $\mathcal{G}$ }
  - ⇒ moyenne sur tous les paramètres
  
- ▶ Et si on utilisait les paramètres optimaux plutôt que la moyenne ?  
Score( $\mathcal{G}$ ) :  $\max_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)$ 
  - ⇒ Paramètres qui « collent » le plus aux données
  - ⇒ Apprentissage de paramètres par max de vraisemblance

▶ Score  $BD(\mathcal{G}) : \int_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)\pi(\Theta|\mathcal{G})d\Theta$

⇒ vraisemblance moyenne sur {RB de structure  $\mathcal{G}$ }

⇒ moyenne sur tous les paramètres

▶ Et si on utilisait les paramètres optimaux plutôt que la moyenne ?

Score( $\mathcal{G}$ ) :  $\max_{\Theta} P(\mathbf{D}|\mathcal{G}, \Theta)$

⇒ Paramètres qui « collent » le plus aux données

⇒ Apprentissage de paramètres par max de vraisemblance

Fondement des scores issus de la théorie de l'information

- ▶ Optimisation des paramètres de  $\mathcal{G}$  par max de vraisemblance  
⇒ score « log-likelihood »

- ▶ Optimisation des paramètres de  $\mathcal{G}$  par max de vraisemblance  
⇒ score « log-likelihood »

## Score log-likelihood (LL)

- ▶  $\text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{i=1}^n \text{Score}_{LL}(X_i|\mathbf{Pa}(X_i), \mathbf{D})$

- ▶  $\text{Score}_{LL}(X_i|\mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$

- ▶ Optimisation des paramètres de  $\mathcal{G}$  par max de vraisemblance  
⇒ score « log-likelihood »

## Score log-likelihood (LL)

- ▶  $\text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{i=1}^n \text{Score}_{LL}(X_i|\mathbf{Pa}(X_i), \mathbf{D})$

- ▶  $\text{Score}_{LL}(X_i|\mathbf{Pa}(X_i), \mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$



En pratique, apprend des graphes trop denses

⇒ « Sur-apprentissage »

⇒ Rajouter une pénalité s'il y a trop d'arcs

## *Score MDL (minimum description length)*

▶  $\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}|$

▶  $|\mathcal{G}| = \sum_{i=1}^n (r_i - 1) \times q_i$

## Score MDL (*minimum description length*)

►  $\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}|$

►  $|\mathcal{G}| = \sum_{i=1}^n (r_i - 1) \times q_i$  : nb de paramètres  $\theta_{ijk}$  à choisir

## Score MDL (minimum description length)

▶  $\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}|$

▶  $|\mathcal{G}| = \sum_{i=1}^n (r_i - 1) \times q_i$  : nb de paramètres  $\theta_{ijk}$  à choisir

▶  $-\frac{1}{2} \log(N)|\mathcal{G}|$  : pénalité

Permet de minimiser la taille mémoire pour stocker le RB



# Scores issus de la théorie de l'information (3/3)

## Score MDL (minimum description length)

▶  $\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}|$

▶  $|\mathcal{G}| = \sum_{i=1}^n (r_i - 1) \times q_i$  : nb de paramètres  $\theta_{ijk}$  à choisir

▶  $-\frac{1}{2} \log(N)|\mathcal{G}|$  : pénalité

Permet de minimiser la taille mémoire pour stocker le RB

## Score BIC (Bayesian Information Criterion)

▶ S'appuie sur le critère BIC [Schwarz (1978)]

▶  $\text{Score}_{BIC}(\mathcal{G}|\mathbf{D}) = \text{Score}_{MDL}(\mathcal{G}|\mathbf{D})$

## Score MDL (minimum description length)

▶  $\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}|$

▶  $|\mathcal{G}| = \sum_{i=1}^n (r_i - 1) \times q_i$  : nb de paramètres  $\theta_{ijk}$  à choisir

▶  $-\frac{1}{2} \log(N)|\mathcal{G}|$  : pénalité

Permet de minimiser la taille mémoire pour stocker le RB

## Score BIC (Bayesian Information Criterion)

▶ S'appuie sur le critère BIC [Schwarz (1978)]

▶  $\text{Score}_{BIC}(\mathcal{G}|\mathbf{D}) = \text{Score}_{MDL}(\mathcal{G}|\mathbf{D})$

## Score AIC (Akaike Information Criterion)

▶ S'appuie sur le critère d'information d'Akaike (1973)

▶  $\text{Score}_{AIC}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - |\mathcal{G}|$

## Exemple d'application (1/2)

$$\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}| \quad \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$$

# Exemple d'application (1/2)

$$\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}| \quad \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$$

A

B

C

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (1/2)

$$\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}| \quad \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{j=1}^{q_j} \sum_{k=1}^{r_j} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$$

A

B

C

►  $\mathbf{D} \implies r_i = 2, \mathcal{G} \implies q_i = 1$  (pas de parent)

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (1/2)

$$\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}| \quad \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$$

A

B

C

►  $\mathbf{D} \implies r_i = 2, \mathcal{G} \implies q_i = 1$  (pas de parent)

►  $i = 1$  (A) : 

$a_1$	$a_2$	$N_{ij}$
3	4	7

 $N_{ij} = \text{total ligne} = 3 + 4$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (1/2)

$$\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}| \quad \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$$

A

B

C

►  $\mathbf{D} \implies r_i = 2, \mathcal{G} \implies q_i = 1$  (pas de parent)

►  $i = 1$  (A) : 

$a_1$	$a_2$	$N_{ij}$
3	4	7

 $N_{ij} = \text{total ligne} = 3 + 4$

$$\text{Score}_{LL}(A) = 3 \log \left( \frac{3}{7} \right) + 4 \log \left( \frac{4}{7} \right) \approx -4,78$$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (1/2)

$$\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}| \quad \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$$

**A**

**B**

**C**

►  $\mathbf{D} \implies r_i = 2, \mathcal{G} \implies q_i = 1$  (pas de parent)

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

►  $i = 1$  (A) : 

$a_1$	$a_2$	$N_{ij}$
3	4	7

 $N_{ij} = \text{total ligne} = 3 + 4$

$$\text{Score}_{LL}(A) = 3 \log \left( \frac{3}{7} \right) + 4 \log \left( \frac{4}{7} \right) \approx -4,78$$

►  $i = 2$  (B) : 

$b_1$	$b_2$
3	4

 $\text{Score}_{LL}(B) \approx -4,78$



# Exemple d'application (1/2)

$$\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}| \quad \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$$

**A**

**B**

**C**

►  $\mathbf{D} \implies r_i = 2, \mathcal{G} \implies q_i = 1$  (pas de parent)

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

►  $i = 1$  (A) : 

$a_1$	$a_2$	$N_{ij}$
3	4	7

 $N_{ij} = \text{total ligne} = 3 + 4$

$$\text{Score}_{LL}(A) = 3 \log \left( \frac{3}{7} \right) + 4 \log \left( \frac{4}{7} \right) \approx -4,78$$

►  $i = 2$  (B) : 

$b_1$	$b_2$
3	4

 $\text{Score}_{LL}(B) \approx -4,78$

►  $i = 3$  (C) : 

$c_1$	$c_2$
4	3

 $\text{Score}_{LL}(C) \approx -4,78$

# Exemple d'application (1/2)

$$\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}| \quad \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$$

**A**

**B**

**C**

►  $\mathbf{D} \implies r_i = 2, \mathcal{G} \implies q_i = 1$  (pas de parent)

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

►  $i = 1$  (A) : 

$a_1$	$a_2$	$N_{ij}$
3	4	7

 $N_{ij} = \text{total ligne} = 3 + 4$

$$\text{Score}_{LL}(A) = 3 \log \left( \frac{3}{7} \right) + 4 \log \left( \frac{4}{7} \right) \approx -4,78$$

►  $i = 2$  (B) : 

$b_1$	$b_2$
3	4

 $\text{Score}_{LL}(B) \approx -4,78$

►  $i = 3$  (C) : 

$c_1$	$c_2$
4	3

 $\text{Score}_{LL}(C) \approx -4,78$

►  $|\mathcal{G}| = \sum_{i=1}^3 (r_i - 1) \times q_i = (1 \times 1) + (1 \times 1) + (1 \times 1) = 3$

# Exemple d'application (1/2)

$$\text{Score}_{MDL}(\mathcal{G}|\mathbf{D}) = \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) - \frac{1}{2} \log(N)|\mathcal{G}| \quad \text{Score}_{LL}(\mathcal{G}|\mathbf{D}) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right)$$

**A**

**B**

**C**

►  $\mathbf{D} \implies r_i = 2, \mathcal{G} \implies q_i = 1$  (pas de parent)

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

►  $i = 1$  (A) : 

$a_1$	$a_2$	$N_{ij}$
3	4	7

 $N_{ij} = \text{total ligne} = 3 + 4$

$$\text{Score}_{LL}(A) = 3 \log \left( \frac{3}{7} \right) + 4 \log \left( \frac{4}{7} \right) \approx -4,78$$

►  $i = 2$  (B) : 

$b_1$	$b_2$
3	4

 $\text{Score}_{LL}(B) \approx -4,78$

►  $i = 3$  (C) : 

$c_1$	$c_2$
4	3


 $\text{Score}_{LL}(C) \approx -4,78$

►  $|\mathcal{G}| = \sum_{i=1}^3 (r_i - 1) \times q_i = (1 \times 1) + (1 \times 1) + (1 \times 1) = 3$

►  $\text{Score}_{MDL}(\mathcal{G}) \approx -4,78 \times 3 - 0,5 \times \log(7) \times 3 \approx -17,259$

## Exemple d'application (2/2)


$$\text{Score}_{MDL}(X_i | \text{Pa}(X_i), \mathbf{D}) = \sum_{k=1}^{r_i} \left[ N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right) \right] - \frac{1}{2} \log(N) \times (r_i - 1) \times q_i$$



A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

# Exemple d'application (2/2)

$$\text{Score}_{MDL}(X_i | \text{Pa}(X_i), \mathbf{D}) = \sum_{k=1}^{r_i} \left[ N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right) \right] - \frac{1}{2} \log(N) \times (r_i - 1) \times q_i$$



►  $\text{Score}_{MDL}(B)$  et  $\text{Score}_{MDL}(C) \approx -4,78 - \frac{1}{2} \log(7) \approx -5.753$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$


►  $(A|B)$  :

	$a_1$	$a_2$	$N_{ij}$
$b_1$	2	1	3
$b_2$	1	3	4

$N_{ij} = \sum$  sur chaque ligne

# Exemple d'application (2/2)

$$\text{Score}_{MDL}(X_i | \text{Pa}(X_i), \mathbf{D}) = \sum_{k=1}^{r_i} \left[ N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right) \right] - \frac{1}{2} \log(N) \times (r_i - 1) \times q_i$$



►  $\text{Score}_{MDL}(B)$  et  $\text{Score}_{MDL}(C) \approx -4,78 - \frac{1}{2} \log(7) \approx -5.753$

A	B	C
$a_1$	$b_1$	$c_1$
$a_1$	$b_1$	$c_2$
$a_1$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_2$	$c_1$
$a_2$	$b_2$	$c_2$
$a_2$	$b_1$	$c_1$

►  $(A|B)$  :


	$a_1$	$a_2$	$N_{ij}$
$b_1$	2	1	3
$b_2$	1	3	4

$N_{ij} = \sum$  sur chaque ligne

$$\begin{aligned} \text{Score}_{MDL}(A|B) &= 2 \times \log \left( \frac{2}{3} \right) + 1 \times \log \left( \frac{1}{3} \right) && \text{(ligne } b_1) \\ &+ 1 \times \log \left( \frac{1}{4} \right) + 3 \times \log \left( \frac{3}{4} \right) && \text{(ligne } b_2) \\ &- \frac{1}{2} \log(7) \times 1 \times 2 \approx -6,105 && \text{(pénalité)} \end{aligned}$$

## Exemple d'application (2/2)

$$\text{Score}_{MDL}(X_i | \text{Pa}(X_i), \mathbf{D}) = \sum_{k=1}^{r_i} \left[ N_{ijk} \log \left( \frac{N_{ijk}}{N_{ij}} \right) \right] - \frac{1}{2} \log(N) \times (r_i - 1) \times q_i$$



►  $\text{Score}_{MDL}(B)$  et  $\text{Score}_{MDL}(C) \approx -4,78 - \frac{1}{2} \log(7) \approx -5.753$

A	B	C
a <sub>1</sub>	b <sub>1</sub>	c <sub>1</sub>
a <sub>1</sub>	b <sub>1</sub>	c <sub>2</sub>
a <sub>1</sub>	b <sub>2</sub>	c <sub>1</sub>
a <sub>2</sub>	b <sub>2</sub>	c <sub>2</sub>
a <sub>2</sub>	b <sub>2</sub>	c <sub>1</sub>
a <sub>2</sub>	b <sub>2</sub>	c <sub>2</sub>
a <sub>2</sub>	b <sub>1</sub>	c <sub>1</sub>

►  $(A|B)$  :

	a <sub>1</sub>	a <sub>2</sub>	N <sub>ij</sub>
b <sub>1</sub>	2	1	3
b <sub>2</sub>	1	3	4

$N_{ij} = \sum$  sur chaque ligne

$$\begin{aligned} \text{Score}_{MDL}(A|B) &= 2 \times \log \left( \frac{2}{3} \right) + 1 \times \log \left( \frac{1}{3} \right) && \text{(ligne } b_1) \\ &+ 1 \times \log \left( \frac{1}{4} \right) + 3 \times \log \left( \frac{3}{4} \right) && \text{(ligne } b_2) \\ &- \frac{1}{2} \log(7) \times 1 \times 2 \approx -6,105 && \text{(pénalité)} \end{aligned}$$

►  $\text{Score}_{MDL}(\mathcal{G}) \approx -6,105 - 5.753 - 5.753 = -17,611$

⇒ Graphe moins probable que celui du slide précédent

- ▶ **Akaike, H. (1973)** « Information theory and an extension of the maximum likelihood principle », Proceedings of the 2nd International Symposium on Information Theory, 267–281
- ▶ **Buntine W. (1991)** « Theory refinement on Bayesian networks », Proceedings of Uncertainty in Artificial Intelligence, 52–60
- ▶ **Colombo D. et Maathuis M.H. (2014)** « Order-Independent Constraint-Based Causal Structure Learning », Journal of Machine Learning Research, 15 :3921–3962
- ▶ **Geiger D. et Heckerman D. (1997)** « A Characterization of the Dirichlet Distribution through Global and Local Parameter Independence », The Annals of Statistics, 25(3) :1344–1369
- ▶ **Heckerman D., Geiger D. et Chickering D. (1995)** « Learning Bayesian Networks : The Combination of Knowledge and Statistical Data », Machine Learning, 20 :197–243



- ▶ **Luo W. (2006)** « Learning Bayesian networks in semi-deterministic systems », Proceedings of the Canadian Conference on Artificial Intelligence, 230–241
- ▶ **Mabrouk A., Gonzales C., Jabet-Chevalier K. et Chojnaki E. (2014)** « An Efficient Bayesian Network Structure Learning Algorithm in the Presence of Deterministic Relations », Proceedings of the European Conference on Artificial Intelligence, 567–572
- ▶ **Meek C. (1995)** « Causal inference and causal explanation with background knowledge », Proceedings of the Conference on Uncertainty in Artificial Intelligence, 403–410
- ▶ **Pearl J. et Verma T. (1991)** « A theory of inferred causation », Proceedings of the 2nd International Conference on Knowledge Representation and Reasoning, 441–452

- ▶ **Rodrigues de Morais, S. Aussem, A. et Corbex M. (2008)** « Handling almost-deterministic relationships in constraint-based Bayesian network discovery : Application to cancer risk factor identification », Proceedings of the European Symposium on Artificial Neural Networks, 101–106
- ▶ **Schwarz, G.E. (1978)** « Estimating the dimension of a model », Annals of Statistics, 6(2) :461–464
- ▶ **Spirtes E., Glymour C. et Scheines R. (2000)** Causation, Prediction and Search, 2nd edition, Springer-Verlag
- ▶ **Verma T. (1993)** « Graphical aspects of causal models », Technical report R-191, UCLA, Computer Science Department