

AIGM 06/12/2018


APPRENTISSAGE ET SÉLECTION DE RÉSEAUX BAYÉSIENS DYNAMIQUES POUR LES PROCESSUS ONLINE NON-STATIONNAIRES.

M. Hourbracq^{1,2} P-H. Wuillemin¹ C. Gonzales¹ P. Baumard²

December 6, 2018

¹Laboratoire d'Informatique de Paris VI (UPMC, CNRS UMR7606) 75004 Paris, France

²Akheros S.A.S. Paris, France



		A		
C	B	0	1	2
0		0.0143	0.0705	0.0591
1	0	0.0373	0.0027	0.0439
2		0.0283	0.0868	0.0570
0		0.0107	0.0529	0.0443
1	1	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427
0		0.0107	0.0529	0.0443
1	2	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427

$P(A, B, C)$

		A		
C	B	0	1	2
0		0.0143	0.0705	0.0591
1	0	0.0373	0.0027	0.0439
2		0.0283	0.0868	0.0570
0		0.0107	0.0529	0.0443
1	1	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427
0		0.0107	0.0529	0.0443
1	2	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427

		A		
B		0	1	2
0		0.0800	0.1600	0.1600
1		0.0600	0.1200	0.1200
2		0.0600	0.1200	0.1200

$$P(A, B, C)$$

$$P(A, B) = \sum_C P(A, B, C)$$

		A		
C	B	0	1	2
0		0.0143	0.0705	0.0591
1	0	0.0373	0.0027	0.0439
2		0.0283	0.0868	0.0570
0	1	0.0107	0.0529	0.0443
1	1	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427
0	2	0.0107	0.0529	0.0443
1	2	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427

$$P(A, B, C)$$

		A		
B		0	1	2
0		0.0800	0.1600	0.1600
1		0.0600	0.1200	0.1200
2		0.0600	0.1200	0.1200

$$P(A, B) = \sum_C P(A, B, C)$$

A		
0	1	2
0.2000	0.4000	0.4000

$$P(A) = \sum_{B,C} P(A, B, C)$$

B		
0	1	2
0.4000	0.3000	0.3000

$$P(B) = \sum_{A,C} P(A, B, C)$$

LOIS JOINTES DISCRÈTES

		A		
C	B	0	1	2
0		0.0143	0.0705	0.0591
1	0	0.0373	0.0027	0.0439
2		0.0283	0.0868	0.0570
0		0.0107	0.0529	0.0443
1	1	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427
0		0.0107	0.0529	0.0443
1	2	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427

A		
0	1	2
0.2000	0.4000	0.4000

B		
0	1	2
0.4000	0.3000	0.3000

		C		
B	A	0	1	2
0		0.1790	0.4668	0.3542
1	0	0.1790	0.4668	0.3542
2		0.1790	0.4668	0.3542
0		0.4405	0.0168	0.5427
1	1	0.4405	0.0168	0.5427
2		0.4405	0.0168	0.5427
0		0.3695	0.2744	0.3561
1	2	0.3695	0.2744	0.3561
2		0.3695	0.2744	0.3561

$$P(A, B, C) = P(A) * P(B) * P(C|B, A)$$

LOIS JOINTES DISCRÈTES

		A		
C	B	0	1	2
0		0.0143	0.0705	0.0591
1	0	0.0373	0.0027	0.0439
2		0.0283	0.0868	0.0570
0		0.0107	0.0529	0.0443
1	1	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427
0		0.0107	0.0529	0.0443
1	2	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427

A		
0	1	2
0.2000	0.4000	0.4000

B		
0	1	2
0.4000	0.3000	0.3000

		C		
B	A	0	1	2
0		0.1790	0.4668	0.3542
1	0	0.1790	0.4668	0.3542
2		0.1790	0.4668	0.3542
0		0.4405	0.0168	0.5427
1	1	0.4405	0.0168	0.5427
2		0.4405	0.0168	0.5427
0		0.3695	0.2744	0.3561
1	2	0.3695	0.2744	0.3561
2		0.3695	0.2744	0.3561

$$P(A, B, C) = P(A) * P(B) * P(C|B, A)$$

$$A \wedge B \mapsto C$$

LOIS JOINTES DISCRÈTES

		A									C				
C	B	0	1	2	A			B			A	0	1	2	
0		0.0143	0.0705	0.0591								0	0.1790	0.4668	0.3542
1	0	0.0373	0.0027	0.0439								1	0.4405	0.0168	0.5427
2		0.0283	0.0868	0.0570	0.2000	0.4000	0.4000	0.4000	0.3000	0.3000		2	0.3695	0.2744	0.3561
0		0.0107	0.0529	0.0443											
1	1	0.0280	0.0020	0.0329											
2		0.0213	0.0651	0.0427											
0		0.0107	0.0529	0.0443											
1	2	0.0280	0.0020	0.0329											
2		0.0213	0.0651	0.0427											

$P(A, B, C) = P(A) * P(B) * P(C|A)$

LOIS JOINTES DISCRÈTES

		A		
C \ B		0	1	2
0		0.0143	0.0705	0.0591
1	0	0.0373	0.0027	0.0439
2		0.0283	0.0868	0.0570
0		0.0107	0.0529	0.0443
1	1	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427
0		0.0107	0.0529	0.0443
1	2	0.0280	0.0020	0.0329
2		0.0213	0.0651	0.0427

A		
0	1	2
0.2000	0.4000	0.4000

B		
0	1	2
0.4000	0.3000	0.3000

C			
A	0	1	2
0	0.1790	0.4668	0.3542
1	0.4405	0.0168	0.5427
2	0.3695	0.2744	0.3561

$$P(A, B, C) = P(A) * P(B) * P(C|A)$$

$A \mapsto C$


$P(A, B, C, D, E, F, G)$?

$P(A, B, C, D, E, F, G)$?

k^7 paramètres

$P(A, B, C, D, E, F, G)$?


k^7 paramètres



RÉSEAUX BAYÉSIENS (DISCRETS) DANS UNE COUILLE DE NOIX

$P(A, B, C, D, E, F, G)$?

K^7 paramètres




$2K + 2K^2 + 3K^3$ paramètres

$P(A, B, C, D, E, F, G)$?

Indépendances dans un BN

k^7 paramètres




$2K + 2K^2 + 3K^3$ paramètres

$P(A, B, C, D, E, F, G)$?

Indépendances dans un BN

$X_i \perp\!\!\!\perp \text{non-desc}_{X_i} \mid \text{parents}_{X_i}$


K^7 paramètres



$2K + 2K^2 + 3K^3$ paramètres

$P(A, B, C, D, E, F, G)$?

K^7 paramètres



$2K + 2K^2 + 3K^3$ paramètres


Indépendances dans un BN

$X_i \perp\!\!\!\perp \text{non-desc}_{X_i} \mid \text{parents}_{X_i}$

Factorisation dans un BN

$P(A, B, C, D, E, F, G)$?

K^7 paramètres



$2K + 2K^2 + 3K^3$ paramètres

Indépendances dans un BN


$X_i \perp\!\!\!\perp \text{non-desc}_{X_i} \mid \text{parents}_{X_i}$

Factorisation dans un BN

$$P(X_1, \dots, X_n) = \prod_i P(X_i \mid \text{parents}_{X_i})$$

$P(A, B, C, D, E, F, G)$?

K^7 paramètres



$2K + 2K^2 + 3K^3$ paramètres

Indépendances dans un BN

$X_i \perp\!\!\!\perp \text{non-desc}_{X_i} \mid \text{parents}_{X_i}$


Factorisation dans un BN

$$P(X_1, \dots, X_n) = \prod_i P(X_i \mid \text{parents}_{X_i})$$

Inférences dans un BN

$P(A, B, C, D, E, F, G)$?

k^7 paramètres



$2K + 2K^2 + 3K^3$ paramètres

Indépendances dans un BN

$X_i \perp\!\!\!\perp \text{non-desc}_{X_i} \mid \text{parents}_{X_i}$

Factorisation dans un BN


$$P(X_1, \dots, X_n) = \prod_i P(X_i \mid \text{parents}_{X_i})$$

Inférences dans un BN

$$\cdot P(A \mid G = 1)$$

$P(A, B, C, D, E, F, G)$?

k^7 paramètres



$2K + 2K^2 + 3K^3$ paramètres

Indépendances dans un BN

$X_i \perp\!\!\!\perp \text{non-desc}_{X_i} \mid \text{parents}_{X_i}$

Factorisation dans un BN


$$P(X_1, \dots, X_n) = \prod_i P(X_i \mid \text{parents}_{X_i})$$

Inférences dans un BN

- $P(A | G = 1)$
- $P(G | A = 0)$

$P(A, B, C, D, E, F, G)$?

K^7 paramètres



$2K + 2K^2 + 3K^3$ paramètres

Indépendances dans un BN

$X_i \perp\!\!\!\perp \text{non-desc}_{X_i} \mid \text{parents}_{X_i}$

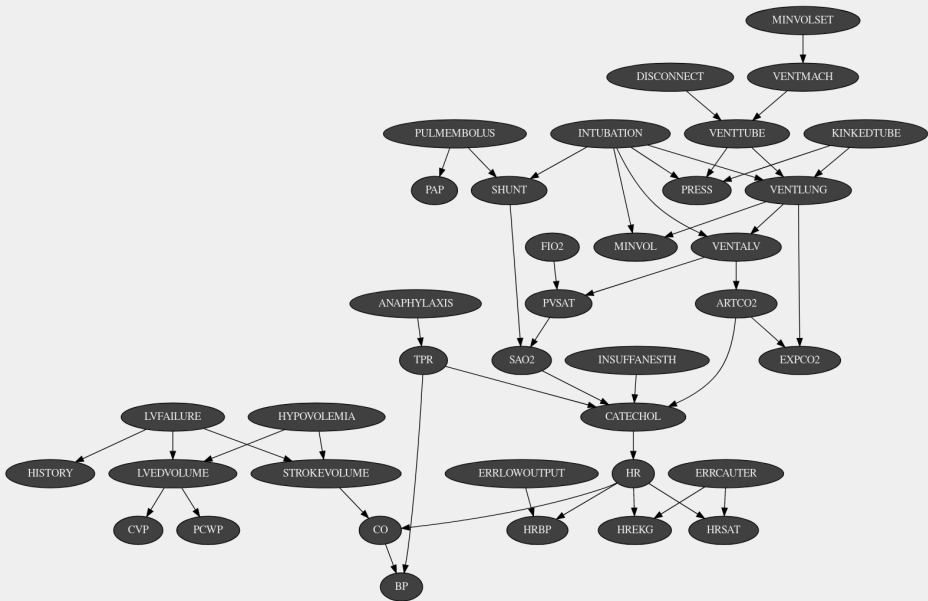
Factorisation dans un BN

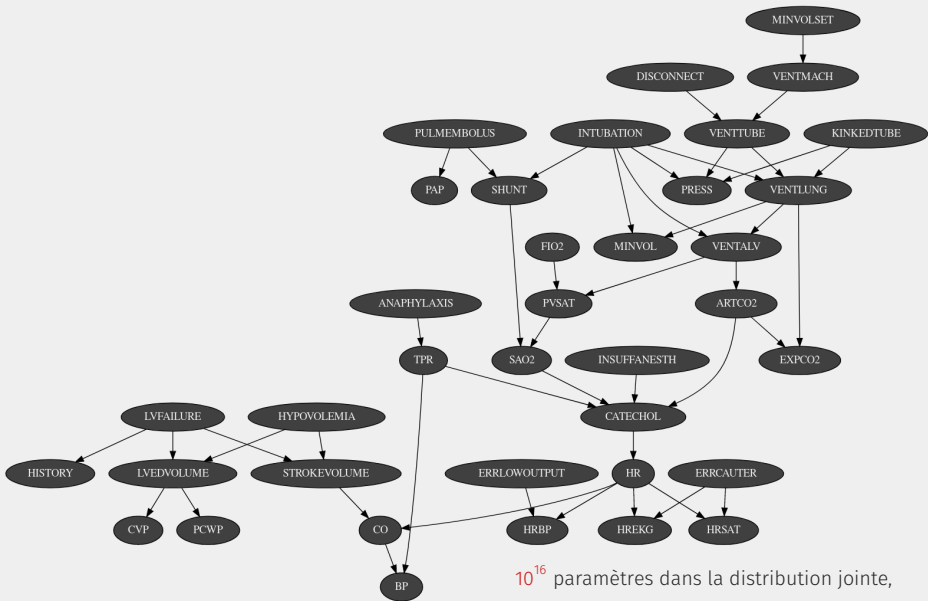
$$P(X_1, \dots, X_n) = \prod_i P(X_i \mid \text{parents}_{X_i})$$

Inférences dans un BN

- $P(A | G = 1)$
- $P(G | A = 0)$
- $P(E | A = 0, G = 1)$

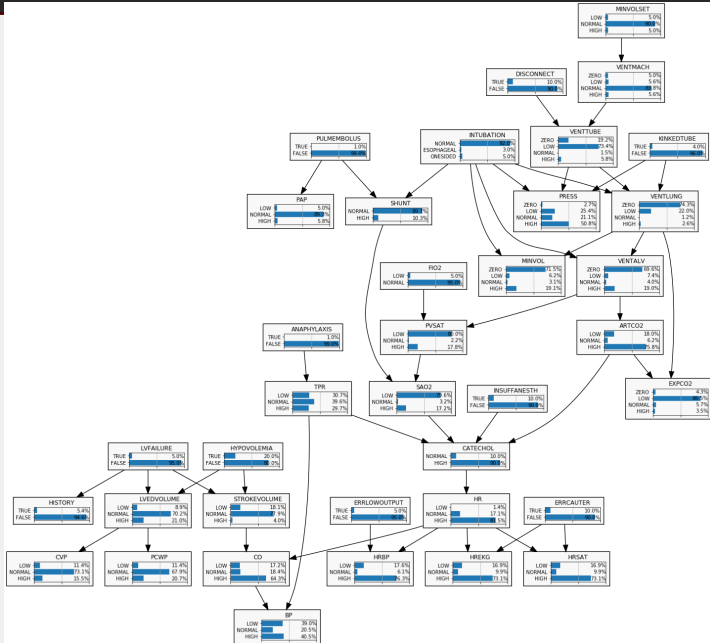
INFÉRENCES DANS UN BN



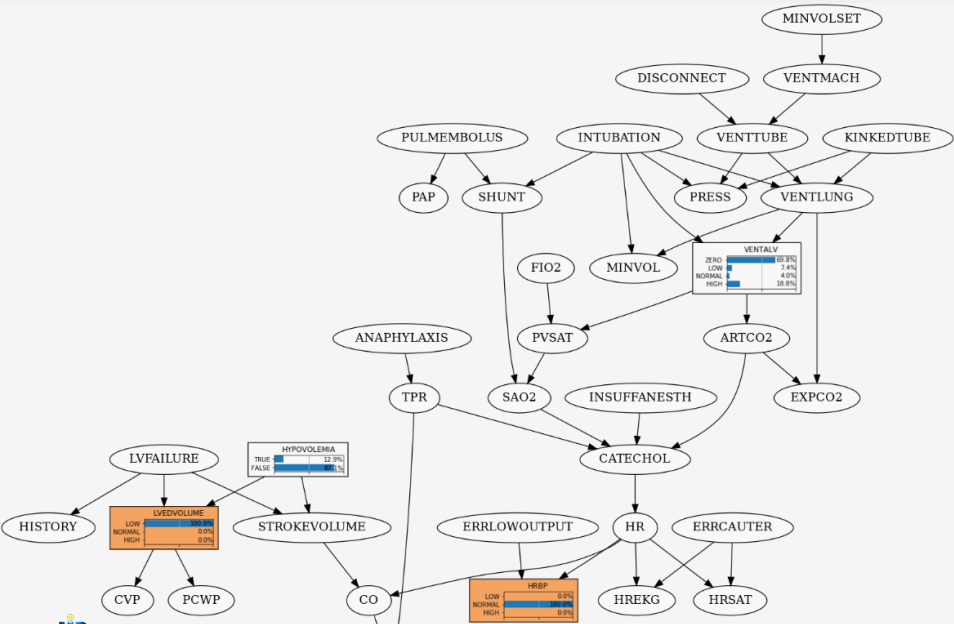


10^{16} paramètres dans la distribution jointe,
752 paramètres dans le BN !

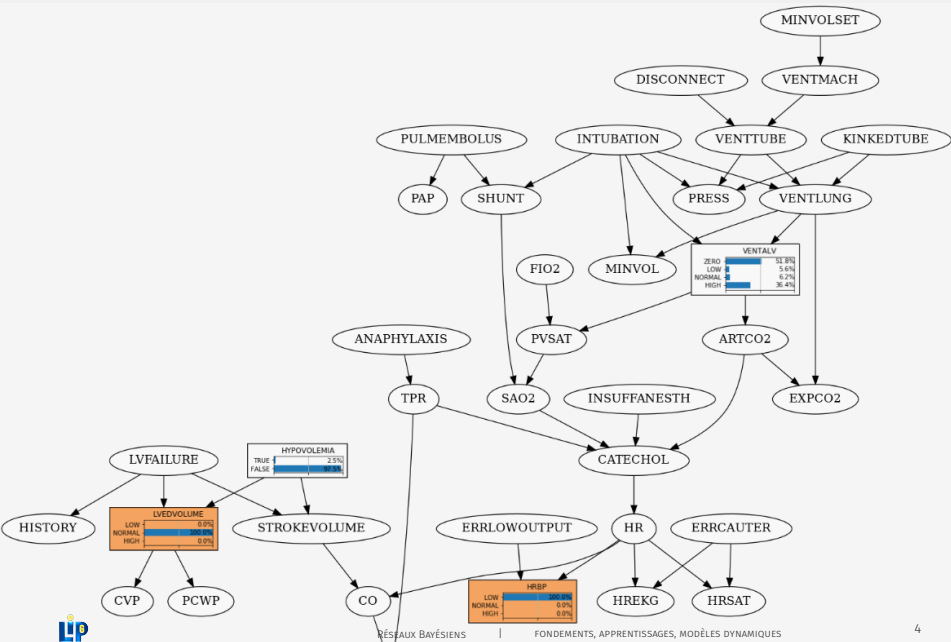
INFÉRENCES DANS UN BN

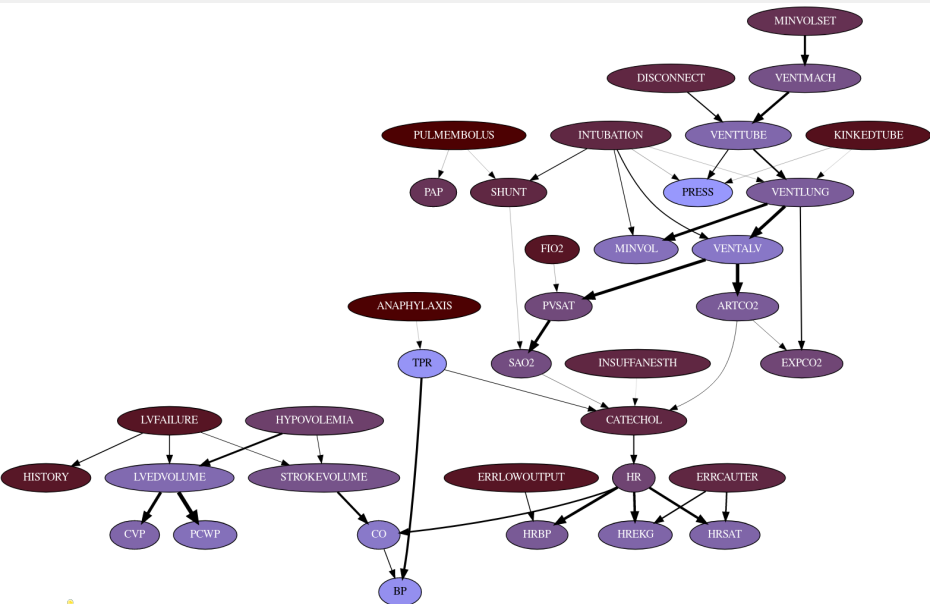


INFÉRENCES DANS UN BN



INFÉRENCES DANS UN BN





Apprentissage dans les réseaux bayésiens

L'apprentissage a pour but d'estimer,

Apprentissage dans les réseaux bayésiens

L'apprentissage a pour but d'**estimer**, à partir d'une **base de données**

Apprentissage dans les réseaux bayésiens

L'apprentissage a pour but d'**estimer**, à partir d'une **base de données** et de **connaissances a priori** :

Apprentissage dans les réseaux bayésiens

L'apprentissage a pour but d'**estimer**, à partir d'une **base de données** et de **connaissances a priori** :

- La structure du réseau bayésien (X parent de Y ?)

Apprentissage dans les réseaux bayésiens

L'apprentissage a pour but d'**estimer**, à partir d'une **base de données** et de **connaissances a priori** :

- La structure du réseau bayésien (X parent de Y ?)
- Les paramètres du réseau bayésien ($P(X = 0 \mid Y = 1)$?)

Apprentissage dans les réseaux bayésiens

L'apprentissage a pour but d'**estimer**, à partir d'une **base de données** et de **connaissances a priori** :

- La structure du réseau bayésien (X parent de Y ?)
- Les paramètres du réseau bayésien ($P(X = 0 \mid Y = 1)$?)

La base de données peut être :

Apprentissage dans les réseaux bayésiens

L'apprentissage a pour but d'**estimer**, à partir d'une **base de données** et de **connaissances a priori** :

- La structure du réseau bayésien (X parent de Y ?)
- Les paramètres du réseau bayésien ($P(X = 0 \mid Y = 1)$?)

La base de données peut être :

- **complète**,
- **incomplète**.

Apprentissage dans les réseaux bayésiens

L'apprentissage a pour but d'**estimer**, à partir d'une **base de données** et de **connaissances a priori** :

- La structure du réseau bayésien (X parent de Y ?)
- Les paramètres du réseau bayésien ($P(X = 0 \mid Y = 1)$?)

La base de données peut être :

- **complète**,
- **incomplète**.

Ce qui donne 4 cadres principaux de l'apprentissage dans les réseaux Bayésiens :

“Apprentissage de {paramètres | **structure**} avec données {**complètes** | incomplètes}”.

Les connaissances a priori sont très variables;

Apprentissage dans les réseaux bayésiens

L'apprentissage a pour but d'**estimer**, à partir d'une **base de données** et de **connaissances a priori** :

- La structure du réseau bayésien (X parent de Y ?)
- Les paramètres du réseau bayésien ($P(X = 0 \mid Y = 1)$?)

La base de données peut être :

- **complète**,
- **incomplète**.

Ce qui donne 4 cadres principaux de l'apprentissage dans les réseaux Bayésiens :
"Apprentissage de {paramètres | **structure**} avec données {**complètes** | incomplètes}".

Les connaissances a priori sont très variables; par exemple :

- **sous-structure du BN connue**,
- **Loi a priori pour certaines variables**, etc.

- But :

- **But** : obtenir automatiquement une structure de réseau bayésien à partir de données.

- **But** : obtenir automatiquement une structure de réseau bayésien à partir de données.
- **En théorie** : Test du χ^2 plus énumération de tous les modèles possibles : OK

- **But** : obtenir automatiquement une structure de réseau bayésien à partir de données.
- **En théorie** : Test du χ^2 plus énumération de tous les modèles possibles : OK
- **En pratique** : Beaucoup de problème mais avant tout :

- **But** : obtenir automatiquement une structure de réseau bayésien à partir de données.
- **En théorie** : Test du χ^2 plus énumération de tous les modèles possibles : OK
- **En pratique** : Beaucoup de problème mais avant tout :

Espace des réseaux bayésiens (Robinson, 1977)

Le nombre de structures possibles pour n nœuds est super-exponentiel.

$$NS(n) = \begin{cases} 1 & , n \leq 1 \\ \sum_{i=1}^n (-1)^{i+1} \cdot C_i^n \cdot 2^{i \cdot (n-i)} \cdot NS(n-1) & , n > 1 \end{cases}$$

Robinson (1977) *Counting unlabelled acyclid digraphs*. In *Lecture Notes in Mathematics : Combinatorial Mathematics V*

La recherche exhaustive n'est pas possible. L'espace est bien trop grand :

$$NS(10) \approx 4.2 \cdot 10^{18} !$$

Tableau général de l'apprentissage de structure

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)
 - algorithme IC/PC
 - algorithme IC*/FCI
 - Autres tests d'indépendances Entropie : 3off2, miic

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)
 - algorithme IC/PC
 - algorithme IC*/FCI
 - Autres tests d'indépendances Entropie : 3off2, miic
- Recherche heuristique (score)

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)
 - algorithme IC/PC
 - algorithme IC*/FCI
 - Autres tests d'indépendances Entropie : 3off2, miic
- Recherche heuristique (score)
 - Dans l'espace des structures

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)
 - algorithme IC/PC
 - algorithme IC*/FCI
 - Autres tests d'indépendances Entropie : 3off2, miic
- Recherche heuristique (score)
 - Dans l'espace des structures (BN ou équivalent de Markov),

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)
 - algorithme IC/PC
 - algorithme IC*/FCI
 - Autres tests d'indépendances Entropie : 3off2, miic
- Recherche heuristique (score)
 - Dans l'espace des structures (BN ou équivalent de Markov),
 - algorithmes essayant de maximiser un score

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)
 - algorithme IC/PC
 - algorithme IC*/FCI
 - Autres tests d'indépendances Entropie : 3off2, miic
- Recherche heuristique (score)
 - Dans l'espace des structures (BN ou équivalent de Markov),
 - algorithmes essayant de maximiser un score (entropie, AIC, BIC, MDL,BD, BDe, BDeu, ...).

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)
 - algorithme IC/PC
 - algorithme IC*/FCI
 - Autres tests d'indépendances Entropie : 3off2, miic
- Recherche heuristique (score)
 - Dans l'espace des structures (BN ou équivalent de Markov),
 - algorithmes essayant de maximiser un score (entropie, AIC, BIC, MDL,BD, BDe, BDeu, ...).

Classe d'équivalence de Markov

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)
 - algorithme IC/PC
 - algorithme IC*/FCI
 - Autres tests d'indépendances Entropie : 3off2, miic
- Recherche heuristique (score)
 - Dans l'espace des structures (BN ou équivalent de Markov),
 - algorithmes essayant de maximiser un score (entropie, AIC, BIC, MDL, BD, BDe, BDeu, ...).

Classe d'équivalence de Markov


Deux réseaux bayésiens sont équivalents si ils représentent le même modèle d'indépendance.

Tableau général de l'apprentissage de structure

- Recherche de relation symétrique + orientation (*causalité*)
 - algorithme **IC/PC**
 - algorithme **IC*/FCI**
 - Autres tests d'indépendances **Entropie : 3off2, miic**
- Recherche heuristique (score)
 - Dans l'espace des structures (**BN** ou **équivalent de Markov**),
 - algorithmes essayant de maximiser un score (**entropie, AIC, BIC, MDL, BD, BDe, BDeu, ...**).

Classe d'équivalence de Markov

Deux réseaux bayésiens sont équivalents si ils représentent le même modèle d'indépendance.



En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

Principe de base (IC, IC*, PC, FCI)

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

Principe de base (IC, IC*, PC, FCI)

1. Construire le graphe (non orienté) des relations de dépendance trouvées statistiquement (χ^2 ou autre) :

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

Principe de base (IC, IC*, PC, FCI)

1. Construire le graphe (non orienté) des relations de dépendance trouvées statistiquement (χ^2 ou autre) :
 - Ajouter des arêtes à partir du graphe vide.

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

Principe de base (IC, IC*, PC, FCI)

1. Construire le graphe (non orienté) des relations de dépendance trouvées statistiquement (χ^2 ou autre) :
 - Ajouter des arêtes à partir du graphe vide.
 - Retirer des arêtes à partir du graphe complet.

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

Principe de base (IC, IC*, PC, FCI)

1. Construire le graphe (non orienté) des relations de dépendance trouvées statistiquement (χ^2 ou autre) :
 - Ajouter des arêtes à partir du graphe vide.
 - Retirer des arêtes à partir du graphe complet.
2. Détecter les V-structures et les orientations qu'elles impliquent.

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

Principe de base (IC, IC*, PC, FCI)

1. Construire le graphe (non orienté) des relations de dépendance trouvées statistiquement (χ^2 ou autre) :
 - Ajouter des arêtes à partir du graphe vide.
 - Retirer des arêtes à partir du graphe complet.
2. Détecter les V-structures et les orientations qu'elles impliquent.
3. Finaliser les orientations en restant dans la même classe d'équivalence de Markov.

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

Principe de base (IC, IC*, PC, FCI)

1. Construire le graphe (non orienté) des relations de dépendance trouvées statistiquement (χ^2 ou autre) :
 - Ajouter des arêtes à partir du graphe vide.
 - Retirer des arêtes à partir du graphe complet.
2. Détecter les V-structures et les orientations qu'elles impliquent.
3. Finaliser les orientations en restant dans la même classe d'équivalence de Markov.

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

Principe de base (IC, IC*, PC, FCI)

1. Construire le graphe (non orienté) des relations de dépendance trouvées statistiquement (χ^2 ou autre) :
 - Ajouter des arêtes à partir du graphe vide.
 - Retirer des arêtes à partir du graphe complet.
2. Détecter les V-structures et les orientations qu'elles impliquent.
3. Finaliser les orientations en restant dans la même classe d'équivalence de Markov.

Écueils principaux

En terme statistique, les relations testables sont symétriques : **corrélation ou indépendance entre variables aléatoires, information mutuelle, etc..**

Par contre, une fois des relations 2 à 2 trouvées, il s'agit de tester certaines indépendances conditionnelles (V-structure) qui forcent les orientations.

Principe de base (IC, IC*, PC, FCI)

1. Construire le graphe (non orienté) des relations de dépendance trouvées statistiquement (χ^2 ou autre) :
 - Ajouter des arêtes à partir du graphe vide.
 - Retirer des arêtes à partir du graphe complet.
2. Détecter les V-structures et les orientations qu'elles impliquent.
3. Finaliser les orientations en restant dans la même classe d'équivalence de Markov.

Écueils principaux

Très grand nombre de tests d'indépendances, chaque test étant très sensible au nombre de données disponibles.

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.).

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres.

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. Vraisemblance :

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. **Vraisemblance** : Coller le mieux aux données ($\max L(T, \Theta : D)$).

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. **Vraisemblance** : Coller le mieux aux données ($\max L(T, \Theta : D)$).
2. **Rasoir d'Occam** :

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. **Vraisemblance** : Coller le mieux aux données ($\max L(T, \Theta : D)$).
2. **Rasoir d'Occam** : Privilégier les topologies T simples aux topologies complexes ($\min Dim(T)$).

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. **Vraisemblance** : Coller le mieux aux données ($\max L(T, \Theta : D)$).
2. **Rasoir d'Occam** : Privilégier les topologies T simples aux topologies complexes ($\min Dim(T)$).
3. **Consistance locale** :

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. **Vraisemblance** : Coller le mieux aux données ($\max L(T, \Theta : D)$).
2. **Rasoir d'Occam** : Privilégier les topologies T simples aux topologies complexes ($\min Dim(T)$).
3. **Consistance locale** : Ajouter un arc 'utile' devrait augmenter le score. Ajouter un arc 'inutile' devrait diminuer le score.

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. **Vraisemblance** : Coller le mieux aux données ($\max L(T, \Theta : D)$).
2. **Rasoir d'Occam** : Privilégier les topologies T simples aux topologies complexes ($\min Dim(T)$).
3. **Consistance locale** : Ajouter un arc 'utile' devrait augmenter le score. Ajouter un arc 'inutile' devrait diminuer le score.
4. **Score équivalence** :

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. **Vraisemblance** : Coller le mieux aux données ($\max L(T, \Theta : D)$).
2. **Rasoir d'Occam** : Privilégier les topologies T simples aux topologies complexes ($\min Dim(T)$).
3. **Consistance locale** : Ajouter un arc 'utile' devrait augmenter le score. Ajouter un arc 'inutile' devrait diminuer le score.
4. **Score équivalence** : Deux réseaux bayésiens Markov-équivalents devraient avoir le même score.

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. **Vraisemblance** : Coller le mieux aux données ($\max L(T, \Theta : D)$).
2. **Rasoir d'Occam** : Privilégier les topologies T simples aux topologies complexes ($\min Dim(T)$).
3. **Consistance locale** : Ajouter un arc 'utile' devrait augmenter le score. Ajouter un arc 'inutile' devrait diminuer le score.
4. **Score équivalence** : Deux réseaux bayésiens Markov-équivalents devraient avoir le même score.
5. **Décomposition locale** :

La recherche exhaustive des relations d'indépendances est inatteignable (nombre de tests prohibitifs, quantité de données nécessaires trop importantes, etc.). Donc utilisation d'une heuristique permettant de quantifier l'adéquation d'une structure à une base de données.

Propriétés des scores

Soient D la base de donnée, T la topologie du réseau bayésien candidat et Θ ses paramètres. Pour qu'un score (une fonction calculée sur un réseau bayésien) soit considéré comme une bonne heuristique, on peut lui demander :

1. **Vraisemblance** : Coller le mieux aux données ($\max L(T, \Theta : D)$).
2. **Rasoir d'Occam** : Privilégier les topologies T simples aux topologies complexes ($\min Dim(T)$).
3. **Consistance locale** : Ajouter un arc 'utile' devrait augmenter le score. Ajouter un arc 'inutile' devrait diminuer le score.
4. **Score équivalence** : Deux réseaux bayésiens Markov-équivalents devraient avoir le même score.
5. **Décomposition locale** : Calculer la modification du score par l'ajout/retrait d'un arc ne doit pas imposer de re-calculer tout le score mais seulement une partie, locale à l'arc modifié.

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

- Soit un espace de recherche,

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

- Soit un espace de recherche,
- Soit une notion de voisinage définie par des opérations élémentaires

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

- Soit un espace de recherche,
- Soit une notion de voisinage définie par des opérations élémentaires
- Soit un score (heuristic) calculable localement.

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

- Soit un espace de recherche,
- Soit une notion de voisinage définie par des opérations élémentaires
- Soit un score (heuristic) calculable localement.

La recherche locale est alors une séquence de voisins telle qu'à partir du point initial, tout élément ultérieur de la séquence augmente le score.
(*Greedy Search*).

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

- Soit un espace de recherche,
- Soit une notion de voisinage définie par des opérations élémentaires
- Soit un score (heuristic) calculable localement.

La recherche locale est alors une séquence de voisins telle qu'à partir du point initial, tout élément ultérieur de la séquence augmente le score. (*Greedy Search*).

Recherche locale dans les réseaux bayésiens

- L'espace est l'espace des réseaux bayésiens (énorme)

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

- Soit un espace de recherche,
- Soit une notion de voisinage définie par des opérations élémentaires
- Soit un score (heuristic) calculable localement.

La recherche locale est alors une séquence de voisins telle qu'à partir du point initial, tout élément ultérieur de la séquence augmente le score. (*Greedy Search*).

Recherche locale dans les réseaux bayésiens

- L'espace est l'espace des réseaux bayésiens (énorme)
- Soit une structure initiale

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

- Soit un espace de recherche,
- Soit une notion de voisinage définie par des opérations élémentaires
- Soit un score (heuristic) calculable localement.

La recherche locale est alors une séquence de voisins telle qu'à partir du point initial, tout élément ultérieur de la séquence augmente le score. (*Greedy Search*).

Recherche locale dans les réseaux bayésiens

- L'espace est l'espace des réseaux bayésiens (énorme)
- Soit une structure initiale
- Les opérations de base

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

- Soit un espace de recherche,
- Soit une notion de voisinage définie par des opérations élémentaires
- Soit un score (heuristic) calculable localement.

La recherche locale est alors une séquence de voisins telle qu'à partir du point initial, tout élément ultérieur de la séquence augmente le score. (*Greedy Search*).

Recherche locale dans les réseaux bayésiens

- L'espace est l'espace des réseaux bayésiens (énorme)
- Soit une structure initiale
- Les opérations de base : ajout/suppression/modification d'un arc (dans le domaine de validité)

L'algorithme de recherche locale est un algorithme générique qui ne demande que quelques hypothèses de base :

Recherche locale

- Soit un espace de recherche,
- Soit une notion de voisinage définie par des opérations élémentaires
- Soit un score (heuristic) calculable localement.

La recherche locale est alors une séquence de voisins telle qu'à partir du point initial, tout élément ultérieur de la séquence augmente le score. (*Greedy Search*).

Recherche locale dans les réseaux bayésiens

- L'espace est l'espace des réseaux bayésiens (énorme)
- Soit une structure initiale
- Les opérations de base : ajout/suppression/modification d'un arc (dans le domaine de validité)

Idée de base : Il faut maximiser la vraisemblance tout en minimisant la dimension.

Idée de base : Il faut maximiser la vraisemblance tout en minimisant la dimension.

score AIC (Akaike, 70)

- Akaike Information Criterion

$$\text{Score}_{\text{AIC}}(T, D) = \log_2 L(\Theta^{\text{MV}}, T : D) - \text{Dim}(T)$$

Idée de base : Il faut maximiser la vraisemblance tout en minimisant la dimension.

score AIC (Akaike, 70)

- Akaike Information Criterion

$$\text{Score}_{\text{AIC}}(T, D) = \log_2 L(\Theta^{\text{MV}}, T : D) - \text{Dim}(T)$$

score BIC (Schwartz, 78)

- Bayesian Information Criterion

$$\text{Score}_{\text{BIC}}(T, D) = \log_2 L(\Theta^{\text{MV}}, T : D) - \frac{1}{2} \cdot \text{Dim}(T) \cdot \log_2 N$$

Idée de base : Il faut maximiser la vraisemblance tout en minimisant la dimension.

score AIC (Akaike, 70)

- Akaike Information Criterion

$$\text{Score}_{\text{AIC}}(T, D) = \log_2 L(\Theta^{\text{MV}}, T : D) - \text{Dim}(T)$$

score BIC (Schwartz, 78)

- Bayesian Information Criterion

$$\text{Score}_{\text{BIC}}(T, D) = \log_2 L(\Theta^{\text{MV}}, T : D) - \frac{1}{2} \cdot \text{Dim}(T) \cdot \log_2 N$$

score MDL (Lam and Bacchus, 93)

- Minimum Description Length

$$\text{Score}_{\text{MDL}}(T, D) = \log_2 L(\Theta^{\text{MV}}, T : D) - |\text{arcs}_T| \cdot \log_2 N - c \cdot \text{Dim}(T)$$

où arcs_T est l'ensemble des arcs du graphe, c est le nombre de bits nécessaire à la représentation d'un paramètre.

dBN (dynamic BN)

dbN (dynamic BN)

Un réseau bayésien dynamique est un réseau bayésien dont les variables sont indicées par le temps t et par i : $X^{(t)} = X_1^{(t)}, \dots, X_N^{(t)}$ et dont la distribution vérifie certaines propriétés :

dbn (dynamic BN)

Un réseau bayésien dynamique est un réseau bayésien dont les variables sont indicées par le temps t et par i : $X^{(t)} = X_1^{(t)}, \dots, X_N^{(t)}$ et dont la distribution vérifie certaines propriétés :

- Markov ordre 1 :

$$P(X^{(t)} \mid X^{(0)}, \dots, X^{(t-1)}) = P(X^{(t)} \mid X^{(t-1)}),$$

dbN (dynamic BN)

Un réseau bayésien dynamique est un réseau bayésien dont les variables sont indicées par le temps t et par i : $X^{(t)} = X_1^{(t)}, \dots, X_N^{(t)}$ et dont la distribution vérifie certaines propriétés :

- Markov ordre 1 :

$$P(X^{(t)} \mid X^{(0)}, \dots, X^{(t-1)}) = P(X^{(t)} \mid X^{(t-1)}),$$

- Homogénéité :

$$P(X^{(t)} \mid X^{(t-1)}) = \dots = P(X^{(1)} \mid X^{(0)}).$$

dbN (dynamic BN)

Un réseau bayésien dynamique est un réseau bayésien dont les variables sont indicées par le temps t et par i : $X^{(t)} = X_1^{(t)}, \dots, X_N^{(t)}$ et dont la distribution vérifie certaines propriétés :

- Markov ordre 1 :

$$P(X^{(t)} | X^{(0)}, \dots, X^{(t-1)}) = P(X^{(t)} | X^{(t-1)}),$$

- Homogénéité :

$$P(X^{(t)} | X^{(t-1)}) = \dots = P(X^{(1)} | X^{(0)}).$$

dBN (dynamic BN)


Un réseau bayésien dynamique est un réseau bayésien dont les variables sont indicées par le temps t et par i : $X^{(t)} = X_1^{(t)}, \dots, X_N^{(t)}$ et dont la distribution vérifie certaines propriétés :

- Markov ordre 1 :

$$P(X^{(t)} \mid X^{(0)}, \dots, X^{(t-1)}) = P(X^{(t)} \mid X^{(t-1)}),$$

- Homogénéité :

$$P(X^{(t)} \mid X^{(t-1)}) = \dots = P(X^{(1)} \mid X^{(0)}).$$



dBN (dynamic BN)


Un réseau bayésien dynamique est un réseau bayésien dont les variables sont indicées par le temps t et par i : $X^{(t)} = X_1^{(t)}, \dots, X_N^{(t)}$ et dont la distribution vérifie certaines propriétés :

- Markov ordre 1 :

$$P(X^{(t)} \mid X^{(0)}, \dots, X^{(t-1)}) = P(X^{(t)} \mid X^{(t-1)}),$$

- Homogénéité :

$$P(X^{(t)} \mid X^{(t-1)}) = \dots = P(X^{(1)} \mid X^{(0)}).$$



- L'adjectif *dynamique* n'est pas forcément bien choisi (puisqu'il y a homogénéité). *Temporel* ou *séquentiel* eût été de meilleur goût.

dBN (dynamic BN)


Un réseau bayésien dynamique est un réseau bayésien dont les variables sont indicées par le temps t et par i : $X^{(t)} = X_1^{(t)}, \dots, X_N^{(t)}$ et dont la distribution vérifie certaines propriétés :

- Markov ordre 1 :

$$P(X^{(t)} \mid X^{(0)}, \dots, X^{(t-1)}) = P(X^{(t)} \mid X^{(t-1)}),$$

- Homogénéité :

$$P(X^{(t)} \mid X^{(t-1)}) = \dots = P(X^{(1)} \mid X^{(0)}).$$



- L'adjectif *dynamique* n'est pas forcément bien choisi (puisqu'il y a homogénéité). *Temporel* ou *séquentiel* eût été de meilleur goût.
- On remarque que d'après la définition, les arcs d'un dBN vont de $X^{(t-1)}$ à X^t ou restent dans le même X^t (le même *timeslice*).

2-TBN

Un réseau bayésien dynamique est défini :

2-TBN

Un réseau bayésien dynamique est défini :

- par les conditions initiales ($p(x^{(0)})$)

2-TBN

Un réseau bayésien dynamique est défini :

- par les conditions initiales ($P(x^{(0)})$)
- par les relations entre des variables à l'instant $t - 1$ et ces même variables à l'instant t (*timeslice*).

2-TBN

Un réseau bayésien dynamique est défini :

- par les conditions initiales ($P(x^{(0)})$)
- par les relations entre des variables à l'instant $t - 1$ et ces même variables à l'instant t (*timeslice*).

Cette représentation, appelée **2TBN** (2 timeslice BN) permet de modéliser un BN virtuellement infini qui en est le développement dans le temps, à partir d'un instant 0.

2-TBN

Un réseau bayésien dynamique est défini :

- par les conditions initiales ($P(x^{(0)})$)
- par les relations entre des variables à l'instant $t - 1$ et ces même variables à l'instant t (*timeslice*).


Cette représentation, appelée **2TBN** (2 timeslice BN) permet de modéliser un BN virtuellement infini qui en est le développement dans le temps, à partir d'un instant 0.

2-TBN

Un réseau bayésien dynamique est défini :

- par les conditions initiales $P(x^{(0)})$
- par les relations entre des variables à l'instant $t - 1$ et ces même variables à l'instant t (*timeslice*).

Cette représentation, appelée **2TBN** (2 timeslice BN) permet de modéliser un BN virtuellement infini qui en est le développement dans le temps, à partir d'un instant 0.




2-TBN

Un réseau bayésien dynamique est défini :

- par les conditions initiales $P(x^{(0)})$
- par les relations entre des variables à l'instant $t - 1$ et ces même variables à l'instant t (timeslice).

Cette représentation, appelée **2TBN** (2 timeslice BN) permet de modéliser un BN virtuellement infini qui en est le développement dans le temps, à partir d'un instant 0.




2-TBN

Un réseau bayésien dynamique est défini :

- par les conditions initiales $P(x^{(0)})$
- par les relations entre des variables à l'instant $t - 1$ et ces même variables à l'instant t (*timeslice*).

Cette représentation, appelée **2TBN** (2 timeslice BN) permet de modéliser un BN virtuellement infini qui en est le développement dans le temps, à partir d'un instant 0.




2-TBN

Un réseau bayésien dynamique est défini :

- par les conditions initiales $P(x^{(0)})$
- par les relations entre des variables à l'instant $t - 1$ et ces même variables à l'instant t (*timeslice*).

Cette représentation, appelée **2TBN** (2 timeslice BN) permet de modéliser un BN virtuellement infini qui en est le développement dans le temps, à partir d'un instant 0.

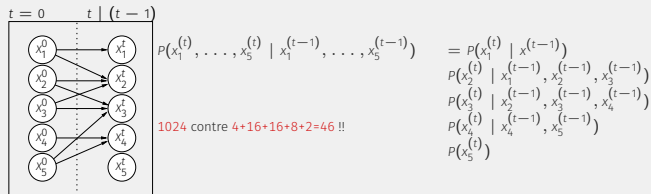



2-TBN


Un réseau bayésien dynamique est défini :

- par les conditions initiales $P(x^{(0)})$
- par les relations entre des variables à l'instant $t - 1$ et ces même variables à l'instant t (*timeslice*).


Cette représentation, appelée **2TBN** (2 timeslice BN) permet de modéliser un BN virtuellement infini qui en est le développement dans le temps, à partir d'un instant 0.








$$P(X^n | X^{n-1}) = \begin{pmatrix} 0.25 & 0 & 0.75 \\ 0.25 & 0.25 & 0.5 \\ 0.25 & 0.5 & 0.25 \end{pmatrix}$$



$$P(X^n | X^{n-1}) = \begin{pmatrix} 0.25 & 0 & 0.75 \\ 0.25 & 0.25 & 0.5 \\ 0.25 & 0.5 & 0.25 \end{pmatrix}$$

Chaîne de Markov

- Une variable d'état discrète (X^n) (à l'instant n).
- Paramètres du modèle :
 - Condition initiale : $P(X^0)$
 - Modèle de transition : $P(X^n | X^{n-1})$




$$P(X^n | X^{n-1}) = \begin{pmatrix} 0.25 & 0 & 0.75 \\ 0.25 & 0.25 & 0.5 \\ 0.25 & 0.5 & 0.25 \end{pmatrix}$$

Chaîne de Markov

- Une variable d'état discrète (X^n) (à l'instant n).
- Paramètres du modèle :
 - Condition initiale : $P(X^0)$
 - Modèle de transition : $P(X^n | X^{n-1})$

Réseau bayésien dynamique équivalent :





$$P(X^n | X^{n-1}) = \begin{pmatrix} 0.25 & 0 & 0.75 \\ 0.25 & 0.25 & 0.5 \\ 0.25 & 0.5 & 0.25 \end{pmatrix}$$

Chaîne de Markov

- Une variable d'état discrète (x^n) (à l'instant n).
- Paramètres du modèle :
 - Condition initiale : $P(x^0)$
 - Modèle de transition : $P(x^n | x^{n-1})$

Réseau bayésien dynamique équivalent :







$$P(X^n | X^{n-1}) = \begin{pmatrix} 0.25 & 0 & 0.75 \\ 0.25 & 0.25 & 0.5 \\ 0.25 & 0.5 & 0.25 \end{pmatrix}$$

Chaîne de Markov

- Une variable d'état discrète (X^n) (à l'instant n).
- Paramètres du modèle :
 - Condition initiale : $P(X^0)$
 - Modèle de transition : $P(X^n | X^{n-1})$

Réseau bayésien dynamique équivalent :



HMM simple

HMM simple

- Une variable d'état discrète (X^n) (à l'instant n).

HMM simple

- Une variable d'état discrète (X^n) (à l'instant n).
- Une variable d'observation discrète (Y^n)

HMM simple

- Une variable d'état discrète (X^n) (à l'instant n).
- Une variable d'observation discrète (Y^n)
- Paramètres du modèle :

HMM simple

- Une variable d'état discrète (X^n) (à l'instant n).
- Une variable d'observation discrète (Y^n)
- Paramètres du modèle :
 - Condition initiale : $P(X^0)$

HMM simple

- Une variable d'état discrète (X^n) (à l'instant n).
- Une variable d'observation discrète (Y^n)
- Paramètres du modèle :
 - Condition initiale : $P(X^0)$
 - Modèle de transition : $P(X^n \mid X^{n-1})$

HMM simple

- Une variable d'état discrète (X^n) (à l'instant n).
- Une variable d'observation discrète (Y^n)
- Paramètres du modèle :
 - Condition initiale : $P(X^0)$
 - Modèle de transition : $P(X^n | X^{n-1})$
 - Modèle d'observation : $P(Y^n | X^n)$

HMM simple


- Une variable d'état discrète (X^n) (à l'instant n).
- Une variable d'observation discrète (Y^n)
- Paramètres du modèle :
 - Condition initiale : $P(X^0)$
 - Modèle de transition : $P(X^n | X^{n-1})$
 - Modèle d'observation : $P(Y^n | X^n)$

Ce qui donne, modélisé comme un réseau bayésien dynamique :

HMM simple

- Une variable d'état discrète (X^n) (à l'instant n).
- Une variable d'observation discrète (Y^n)
- Paramètres du modèle :
 - Condition initiale : $P(X^0)$
 - Modèle de transition : $P(X^n | X^{n-1})$
 - Modèle d'observation : $P(Y^n | X^n)$


Ce qui donne, modélisé comme un réseau bayésien dynamique :



HMM simple

- Une variable d'état discrète (X^n) (à l'instant n).
- Une variable d'observation discrète (Y^n)
- Paramètres du modèle :
 - Condition initiale : $P(X^0)$
 - Modèle de transition : $P(X^n | X^{n-1})$
 - Modèle d'observation : $P(Y^n | X^n)$

Ce qui donne, modélisé comme un réseau bayésien dynamique :



- A priori, très complexe : nombre de nœuds importants

- A priori, très complexe : nombre de nœuds importants
- A priori, très complexe : "causes" communes dans un passé (lointain)

- A priori, très complexe : nombre de nœuds importants
- A priori, très complexe : "causes" communes dans un passé (lointain)

Complexité

NP-difficile

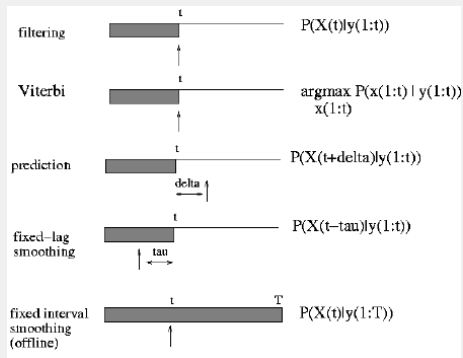
- A priori, très complexe : nombre de nœuds importants
- A priori, très complexe : "causes" communes dans un passé (lointain)

Complexité

NP-difficile

$$P(X_t^i \mid y_{[1:r]}) ?$$

- $r = t$: *Filtering*
- $r > t$: *Smoothing*
- $r < t$: *Prediction*
- MPE : *Viterbi*



Soit une base de donnée de séquences $(D^{(j,t)})$, où

- j est l'indice de la séquence $j \in J$
- t l'indice du temps dans la séquence $t \in \{0, \dots, T_j\}$

Soit une base de donnée de séquences $(D^{(j,t)})$, où

- j est l'indice de la séquence $j \in J$
- t l'indice du temps dans la séquence $t \in \{0, \dots, T_j\}$

La stationnarité et la propriété de Markov d'ordre 1 nous permettent de spécifier :

Apprentissage d'un dBN

Soit une base de donnée de séquences $(D^{(j,t)})$, où

- j est l'indice de la séquence $j \in J$
- t l'indice du temps dans la séquence $t \in \{0, \dots, T_j\}$

La stationnarité et la propriété de Markov d'ordre 1 nous permettent de spécifier :

Apprentissage d'un dBN

Un dBN s'apprend en deux apprentissages :

Soit une base de donnée de séquences $(D^{(j,t)})$, où

- j est l'indice de la séquence $j \in J$
- t l'indice du temps dans la séquence $t \in \{0, \dots, T_j\}$

La stationnarité et la propriété de Markov d'ordre 1 nous permettent de spécifier :


Apprentissage d'un dBN

Un dBN s'apprend en deux apprentissages :


- $P(X^{(0)})$ est un BN appris sur la base $(D^{(j,0)})_{j \in J}$
- $P(X^{(t)} | X^{(t-1)})$ est un BN appris sur la base $(D^{(j,t-1)}, D^{(j,t)})_{t \in 1, \dots, T_j, j \in J}$ sous contrainte d'aucun arc dans $X^{(t-1)}$.

Soit une CdM représentant un processus de vieillissement d'un composant A.


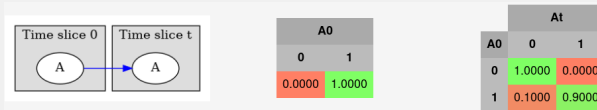
Soit une CdM représentant un processus de vieillissement d'un composant A.




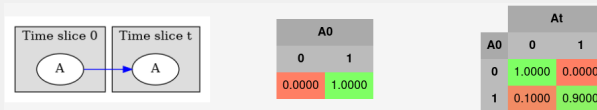
Soit une CdM représentant un processus de vieillissement d'un composant A.



Soit une CdM représentant un processus de vieillissement d'un composant A.


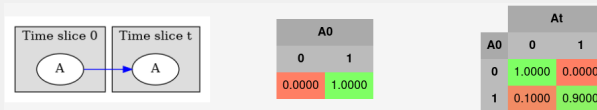


Soit une CdM représentant un processus de vieillissement d'un composant A.




Maintenance en $t = 10$: $A^{(10)} = 1$

Soit une CdM représentant un processus de vieillissement d'un composant A.



Maintenance en $t = 10$: $A^{(10)} = 1$




On ne peut pas représenter une intervention sans supprimer la stationnarité du modèle ...

On peut retrouver la stationnarité en introduisant une variable de contrôle C .


STATIONNARITÉ (2)

On peut retrouver la stationnarité en introduisant une variable de contrôle C .




		A0	
C0		0	1
0	0	0.0000	1.0000
1	1	0.0000	1.0000

		At	
A0	Ct	0	1
0	0	1.0000	0.0000
1	0	0.1000	0.9000
0	1	0.0000	1.0000
1	1	0.0000	1.0000




STATIONNARITÉ (2)

On peut retrouver la stationnarité en introduisant une variable de contrôle C .



		A0	
C0		0	1
0	0	0.0000	1.0000
1	1	0.0000	1.0000


		At	
A0	Ct	0	1
0	0	1.0000	0.0000
1	0	0.1000	0.9000
0	1	0.0000	1.0000
1	1	0.0000	1.0000



Maintenance en $t = 10$: $C^{(10)} = 1$ sinon $C^{(t)} = 0$


STATIONNARITÉ (2)

On peut retrouver la stationnarité en introduisant une variable de contrôle C .




	A0	
C0	0	1
0	0.0000	1.0000
1	0.0000	1.0000

		At	
A0	Ct	0	1
0	0	1.0000	0.0000
1	0	0.1000	0.9000
0	1	0.0000	1.0000
1	1	0.0000	1.0000




Maintenance en $t = 10$: $C^{(10)} = 1$ sinon $C^{(t)} = 0$




STATIONNARITÉ (2)

On peut retrouver la stationnarité en introduisant une variable de contrôle C .




	A0	
C0	0	1
0	0.0000	1.0000
1	0.0000	1.0000


		At	
A0	Ct	0	1
0	0	1.0000	0.0000
1	0	0.1000	0.9000
0	1	0.0000	1.0000
1	1	0.0000	1.0000




Maintenance en $t = 10$: $C^{(10)} = 1$ sinon $C^{(t)} = 0$



Le coût des variables de contrôle peut être prohibitif. On aimerait un modèle dynamique non stationnaire ...






- Streamed data (online)




- Streamed data, non i.i.d.
- Non homogène



MOTIVATIONS



- Streamed data, non i.i.d.
- Non homogène
- Modèle probabiliste dynamique
- Identification DBN et apprentissage incrémental





- Streamed data, non i.i.d.
- Non homogène
- Modèle probabiliste dynamique
- Identification DBN et apprentissage incrémental
- $freq(\text{change}) \ll freq(\text{sampling})$





Outline

- Streamed data, non i.i.d.
 - Non homogène
 - Modèle probabiliste dynamique
 - Identification DBN et apprentissage incrémental
 - $freq(\text{change}) \ll freq(\text{sampling})$
 - Applications: computer security, bank fraud
- DBNs , ns-DBNs






Outline

- Streamed data, non i.i.d.
 - Non homogène
 - Modèle probabiliste dynamique
 - Identification DBN et apprentissage incrémental
 - $freq(\text{change}) \ll freq(\text{sampling})$
 - Applications: computer security, bank fraud
- DBNs , ns-DBNs





Outline

- Streamed data, non i.i.d.
 - Non homogène
 - Modèle probabiliste dynamique
 - Identification DBN et apprentissage incrémental
 - $freq(\text{change}) \ll freq(\text{sampling})$
 - Applications: computer security, bank fraud
- DBNs , ns-DBNs
 - Identification et apprentissage





Outline

- Streamed data, non i.i.d.
 - Non homogène
 - Modèle probabiliste dynamique
 - Identification DBN et apprentissage incrémental
 - $freq(\text{change}) \ll freq(\text{sampling})$
 - Applications: computer security, bank fraud
- DBNs , ns-DBNs
 - Identification et apprentissage
 - Expériences - fenêtres statiques





Outline

- Streamed data, non i.i.d.
 - Non homogène
 - Modèle probabiliste dynamique
 - Identification DBN et apprentissage incrémental
 - $freq(\text{change}) \ll freq(\text{sampling})$
 - Applications: computer security, bank fraud
- DBNs , ns-DBNs
 - Identification et apprentissage
 - Expériences - fenêtres statiques
 - Change-point



Outline


- Streamed data, non i.i.d.
 - Non homogène
 - Modèle probabiliste dynamique
 - Identification DBN et apprentissage incrémental
 - $freq(\text{change}) \ll freq(\text{sampling})$
 - Applications: computer security, bank fraud
- DBNs , ns-DBNs
 - Identification et apprentissage
 - Expériences - fenêtres statiques
 - Change-point
 - Expériences - fenêtres dynamiques




Outline

- Streamed data, non i.i.d.
- Non homogène
- Modèle probabiliste dynamique
- Identification DBN et apprentissage incrémental
- $freq(\text{change}) \ll freq(\text{sampling})$
- Applications: computer security, bank fraud
- DBNs , ns-DBNs
- Identification et apprentissage
- Expériences - fenêtres statiques
- Change-point
- Expériences - fenêtres dynamiques
- Conclusion, logs apache


QU'EST-CE QU'UN DBN ?




QU'EST-CE QU'UN DBN ?



$t = 0$ $t = 1$ $t = 2$ $t = 3$...




QU'EST-CE QU'UN DBN ?




$$Pa(X_i[t]) \subset X[t-1] \cup X[t] \setminus \{X_i[t]\}$$

QU'EST-CE QU'UN DBN ?



$t = 0$ $t = 1$ $t = 2$ $t = 3$...



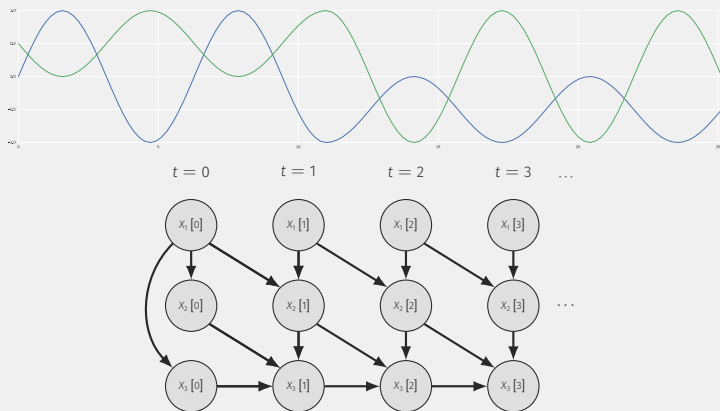
· propriété de Markov du premier ordre

· homogénéité

$$\text{Pa}(X_i[t]) \subset X[t-1] \cup X[t] \setminus \{X_i[t]\}$$

$$\forall t, t' \in [1, \tau] : P_i^t = P_i^{t'}$$

QU'EST-CE QU'UN DBN ?





· propriété de Markov du premier ordre

· homogénéité

$$\text{Pa}(X_i[t]) \subset X[t-1] \cup X[t] \setminus \{X_i[t]\}$$

$$\forall t, t' \in [1, \tau] : P_i^t = P_i^{t'}$$


QU'EST-CE QU'UN DBN ?



Représentation compacte de P

$$P(X[1] \dots, X[\tau]) = \prod_{i=1}^n \prod_{t=1}^{\tau} P(X_i[t] \mid \text{Pa}(X_i[t]))$$

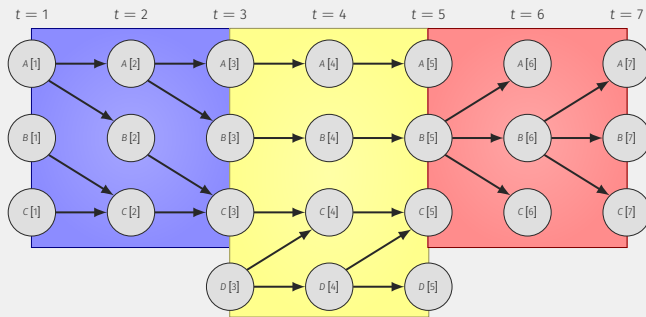
QU'EST-CE QU'UN DBN ?



Représentation compacte de P



$$P(X[1] \dots, X[\tau]) = \prod_{i=1}^n \prod_{t=1}^{\tau} P(X_i[t] \mid \text{Pa}(X_i[t]))$$

Non-stationary dynamic bayesian network.




- Perte d'homogénéité sur l'ensemble du processus
- Spécifier $P(X_i[t] \mid \text{Pa}(X_i[t]))$ (homogène) pour chaque époque
- Homogénéité par morceaux (algorithmes efficaces)



IDENTIFIER ÉPOQUES ET DBN ASSOCIÉ À CHACUNE





$$\mathcal{LL}_i(\mathbf{w}, \text{DBN}_i)$$





IDENTIFIER ÉPOQUES ET DBN ASSOCIÉ À CHACUNE





$$\mathcal{L}\mathcal{L}_i(\mathbf{w}, \text{DBN}_i) \sim \mathcal{N}(\mu_i, \sigma_i^2)$$





IDENTIFIER ÉPOQUES ET DBN ASSOCIÉ À CHACUNE





$$\mathcal{L}\mathcal{L}_i(\mathbf{w}, \text{DBN}_i) \sim \mathcal{N}(\mu_i, \sigma_i^2)$$








IDENTIFIER ÉPOQUES ET DBN ASSOCIÉ À CHACUNE








$$\mathcal{L}\mathcal{L}_i(\mathbf{w}, \text{DBN}_i) \sim \mathcal{N}(\mu_i, \sigma_i^2)$$



IDENTIFIER ÉPOQUES ET DBN ASSOCIÉ À CHACUNE






IDENTIFIER ÉPOQUES ET DBN ASSOCIÉ À CHACUNE





$$\operatorname{argmax}_i \mathcal{L} \mathcal{L}_i (w, \text{DBN}_i)$$


IDENTIFIER ÉPOQUES ET DBN ASSOCIÉ À CHACUNE



----->





----->





$$\operatorname{argmax}_i \mathcal{L} \mathcal{L}_i (w, \text{DBN}_i)$$

Learning with new and/or missing variables.



A [t]	B [t]	C [t]	D [t]
0	1	5	4
3	6	9	5
8	2	12	3
1	5	3	8
6	7	5	1
3	0	4	7



Learning with new and/or missing variables.




A [t]	B [t]	C [t]	D [t]
0	1	5	4
3	6	9	5
8	2	12	3
1	5	3	8
6	7	5	1
3	0	4	7

rejeter $D [t]$ dans DB

Learning with new and/or missing variables.





A [t]	B [t]	C [t]	D [t]
0	1	5	4
3	6	9	5
8	2	12	3
1	5	3	8
6	7	5	1
3	0	4	7




A [t]	B [t]	C [t]
0	1	5
3	6	9
8	2	12
1	5	3
6	7	5
3	0	4

rejeter $D [t]$ dans DB

Learning with new and/or missing variables.



A [t]	B [t]	C [t]	D [t]
0	1	5	4
3	6	9	5
8	2	12	3
1	5	3	8
6	7	5	1
3	0	4	7




A [t]	B [t]	C [t]
0	1	5
3	6	9
8	2	12
1	5	3
6	7	5
3	0	4






rejeter $D [t]$ dans DB

calculer $P (C [t + 1] | C [t])$


$$\sum_D P (C [t + 1] | C [t], D [t]) \cdot P (D [t])$$




EXPÉRIENCES - GÉNÉRATION DB




EXPÉRIENCES - GÉNÉRATION DB




$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
0	1	5
3	6	9
...		




$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
8	2	12
1	5	3
...		



$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
3	7	4
6	1	9
...		




$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
3	9	2
8	6	1
...		




$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
11	3	9
7	5	6
...		

EXPÉRIENCES - GÉNÉRATION DB




↓

$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
0	1	5
3	6	9
...		




↓

$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
8	2	12
1	5	3
...		




↓

$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
3	7	4
6	1	9
...		



↓

$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
3	9	2
8	6	1
...		

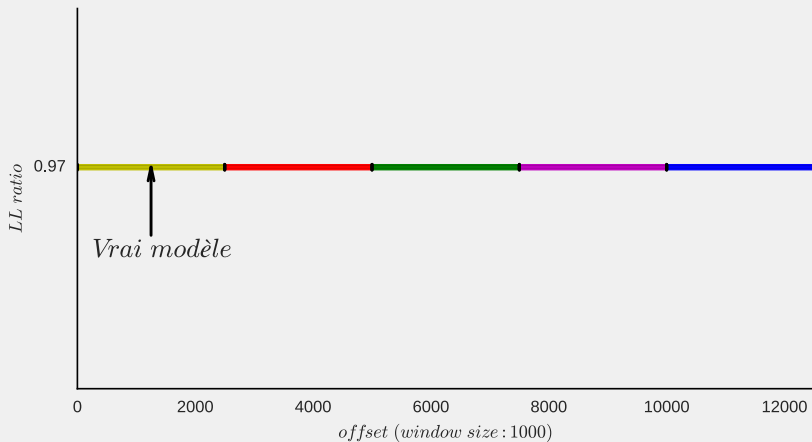


↓


$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
11	3	9
7	5	6
...		

↓


$x_1 [t]$	$x_2 [t]$	$x_3 [t]$
0	1	5
...		
8	2	12
...		
3	7	4
...		




Comment interpréter les expériences.




Comment interpréter les expériences.



Comment interpréter les expériences.




Comment interpréter les expériences.



Comment interpréter les expériences.


FP : Faux positif (transition erronée)



Comment interpréter les expériences.

FP : Faux positif (transition erronée)

TP : Vrai positif (transition correcte)




Comment interpréter les expériences.

FP : Faux positif (transition erronée)

FN : Faux négatif (transition ratée)

TP : Vrai positif (transition correcte)



Comment interpréter les expériences.


FP : Faux positif (transition erronée)

FN : Faux négatif (transition ratée)


TP : Vrai positif (transition correcte)

fp, tp, fn, tn : as above, for events


EXPERIMENTS - STATIC WINDOWS




Résultats pour des époques de 5K observations, $Hellinger < 0.8$, fenêtres statiques



Résultats pour des époques de 2K5 observations, *Hellinger* < 0.8, fenêtres statiques



Résultats pour des époques de 10K observations, $Hellinger < 0.8$, fenêtres statiques




Résultats pour des époques de 10K observations, $Hellinger < 0.8$, fenêtres statiques


RÉSULTATS SYNTHÉTIQUES - FENÊTRE STATIQUE

<i>epoch</i>	<i>window size</i>	<i>FN</i>	<i>FP</i>	<i>TP</i>	<i>average error</i>
2500	1000	0.5	0.0	0.5	251.046
2500	2000	0.602	0.0	1.0	521.052
5000	1500	0.101	0.035	0.965	351.216
5000	3000	0.0	0.06	0.94	752.1
10000	1500	0.0	0.131	0.869	381.356
10000	3000	0.1017	0.0083	0.992	772.81
15000	2000	0.0	0.204	0.795	512.82



CHANGE-POINT




CHANGE-POINT





CHANGE-POINT




CHANGE-POINT



— $\ln \mathcal{L}(x < i, \mu_l, \sigma_l^2) + \ln \mathcal{L}(x \geq i, \mu_r, \sigma_r^2)$
— $\ln \mathcal{L}(x < i, \mu_l, \sigma_l^2)$
— $\ln \mathcal{L}(x \geq i, \mu_r, \sigma_r^2)$
— $ll = \ln \mathcal{L}(x, \mu, \sigma^2)$
— $1.1 * ll$

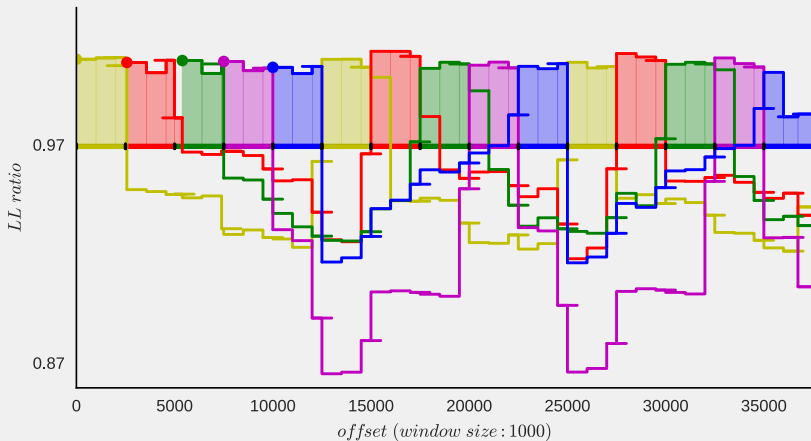


EXPÉRIENCES - FENÊTRE DYNAMIQUE




Résultats pour des époques de 2K5 observations, *Hellinger* < 0.8, fenêtres statiques

EXPÉRIENCES - FENÊTRE DYNAMIQUE



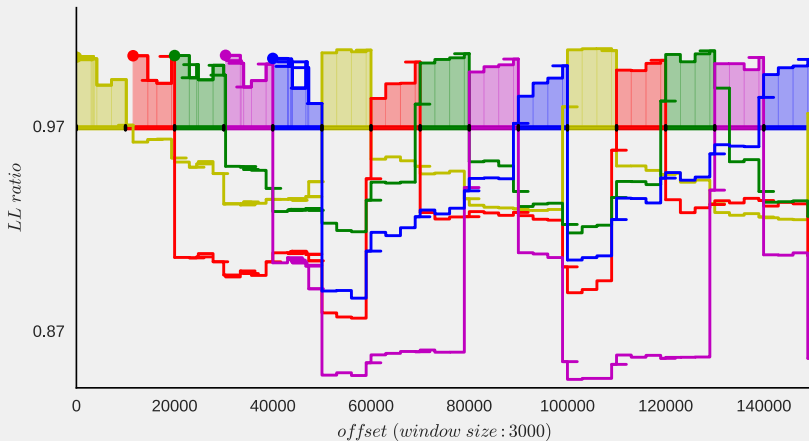
Résultats pour des époques de 2K5 observations, $Hellinger < 0.8$, fenêtres dynamiques

EXPÉRIENCES - FENÊTRE DYNAMIQUE



Résultats pour des époques de 10K observations, $Hellinger < 0.8$, fenêtres statiques

EXPÉRIENCES - FENÊTRE DYNAMIQUE



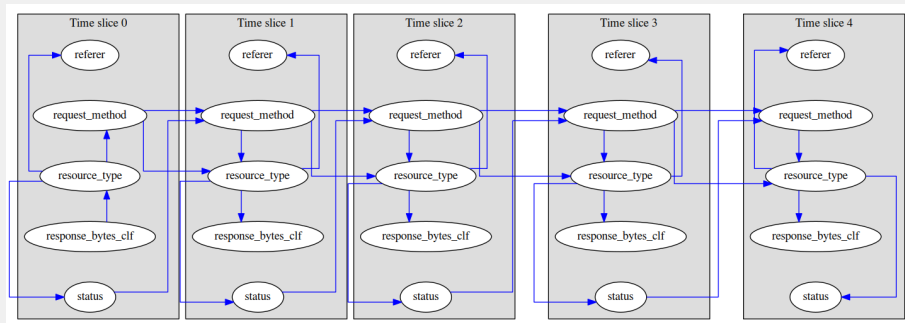
Résultats pour des époques de 10K observations, $Hellinger < 0.8$, fenêtres dynamiques

RÉSULTATS SYNTHÉTIQUES - FENÊTRE DYNAMIQUE

<i>epoch</i>	<i>window size</i>	<i>FN</i>	<i>FP</i>	<i>TP</i>	<i>average error</i>	<i>FN</i>	<i>FP</i>	<i>TP</i>	<i>average error</i>
2500	1000	0.5	0.0	0.5	251.046	0.0	0.0	1.0	4.399
2500	2000	0.602	0.0	1.0	521.052	0.0	0.0	1.0	2.435
5000	1500	0.101	0.035	0.965	351.216	0.0	0.0	1.0	3.0966
5000	3000	0.0	0.06	0.94	752.1	0.0	0.0	1.0	8.702
10000	1500	0.0	0.131	0.869	381.356	0.0	0.0	1.0	32.923
10000	3000	0.1017	0.0083	0.992	772.81	0.0	0.0	1.0	19.559
15000	2000	0.0	0.204	0.795	512.82	0.0	0.0	1.0	8.551

- Réseaux bayésiens dynamiques non-homogènes
 - Comme une collection de modèles avec structures et/ou paramètres différents
 - Homogénéité par morceaux
- Identification correcte du nombre de transitions, de leur positions et des modèles
- Évènements singuliers et outliers ?
- Quel serait le modèle de transition entre époques ?

```
173.36.240.171 -- [01/Jun/2015 : 00 : 01 : 19 + 0000]" GET/projects/scapy/HTTP/1.1" 2006205" http :  
//r.search.yahoo.com/_ylt = AwrTccnLoGtVzh8ANUnnllQ;_ylu =  
X3oDMTByYnR1Zmd1BGNvbG8DZ3ExBHBvcwMyBHZ0aWQDBHNlYwNzcg -- /RV = 2 /RE =  
1433145676 /RO = 10 /RU = http%03a%02f%02fsecdev.org%02fprojects%02fscapy%02f/RK = 0 /RS =  
DV3KSkU3cpgfOsdls5DOVKn1zrs - "" Mozilla/5.0(WindowsNT6.1; WOW64; rv :  
38.0)Gecko/20100101Firefox/38.0"
```



- 1 mois de logs - 29341 adresse ip, quelques anomalies / patterns d'attaque(5)
- 33 modèles découverts
- Pour chaque ip, un set de modèles
- Un modèle apparaît seulement pendant les attaques et inclut tous les patterns connus