

Inférence dans les réseaux bayésiens

Christophe Gonzales

LIP6 – Université Paris 6, France

Plan du cours 2

- 1 L'algorithme de Shafer-Shenoy
- 2 D'autres algorithmes d'inférence
- 3 Construction d'un arbre de jonction

Inférence dans les réseaux bayésiens

2/67

Une présentation unifiée des algorithmes d'inférence

Définition

Inférence : calculer des probabilités (marginales, a priori, a posteriori, etc.).

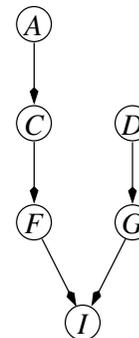
Les algorithmes d'inférence :

Lazy propagation
Shafer-Shenoy
Jensen (HUGIN)
Pearl

) méthodes non orientées
) méthode orientée

Osons le calcul des probabilités a priori

$$P(A, C, D, F, G, I) = P(A)P(C|A)P(F|C)P(D)P(G|D)P(I|F, G)$$



Calcul de $P(I)$?

Inférence dans les réseaux bayésiens

3/67

Inférence dans les réseaux bayésiens

4/67

Shafer-Shenoy brut de fonderie

$$P(A, C, D, F, G, I) = P(A)P(C|A)P(F|C)P(D)P(G|D)P(I|F, G)$$

$$P(I) = \sum_G \left(\sum_F \left(\sum_D \left(\sum_C \left(\sum_A P(A, C, D, F, G, I) \right) \right) \right) \right)$$

$$\sum_A P(A, C, D, F, G, I) = \underbrace{\left(\sum_A P(A)P(C|A) \right)}_{P(C)} P(F|C)P(D)P(G|D)P(I|F, G)$$

$$\sum_A P(A, C, D, F, G, I) = P(C)P(F|C)P(D)P(G|D)P(I|F, G)$$

$$\sum_C \sum_A P(A, C, D, F, G, I) = \underbrace{\left(\sum_C P(C)P(F|C) \right)}_{P(F)} P(D)P(G|D)P(I|F, G)$$

Dissection du produit de deux probabilités

$$P(A, B|C) = \begin{matrix} & \overbrace{c_1}^{a_1} & \overbrace{c_2}^{a_2} & & \overbrace{c_1}^{a_1} & \overbrace{c_2}^{a_2} & & \overbrace{c_1}^{a_1} & \overbrace{c_2}^{a_2} \\ \begin{pmatrix} 0,15 & 0,18 \\ 0,15 & 0,12 \end{pmatrix} & \begin{pmatrix} 0,07 & 0,56 \\ 0,63 & 0,14 \end{pmatrix} & b_1 = & \begin{pmatrix} 0,5 & 0,6 \\ 0,5 & 0,4 \end{pmatrix} & \begin{pmatrix} 0,1 & 0,8 \\ 0,9 & 0,2 \end{pmatrix} & b_2 & \times & \begin{pmatrix} 0,3 & 0,7 \end{pmatrix} \\ & & & \underbrace{\hspace{10em}}_{P(B|A, C)} & & & & \underbrace{\hspace{2em}}_{P(A)} \end{matrix}$$

$$P(I, C|B) = \begin{matrix} & \overbrace{c_1}^{b_1} & \overbrace{c_2}^{b_2} & & \overbrace{c_1}^{P(I|C)} & \overbrace{c_2}^{P(I|C)} & & \overbrace{c_1}^{P(C)} & \overbrace{c_2}^{P(C)} \\ \begin{pmatrix} 0,48 & 0,08 \\ 0,12 & 0,32 \end{pmatrix} & \begin{pmatrix} 0,48 & 0,08 \\ 0,12 & 0,32 \end{pmatrix} & i_1 = & \begin{pmatrix} 0,8 & 0,2 \\ 0,2 & 0,8 \end{pmatrix} & i_2 & \times & \begin{pmatrix} 0,6 & 0,4 \end{pmatrix} \\ & & & \underbrace{\hspace{10em}}_{P(I|C)} & & & & \underbrace{\hspace{2em}}_{P(C)} \end{matrix}$$

Shafer-Shenoy graphique (1/6)

Séquence d'élimination

A C D F G

$$P(A, C, D, F, G, I) = P(A)P(C|A)P(F|C)P(D)P(G|D)P(I|F, G)$$

A AC FC D GD IFG
 $P(A)$ $P(C|A)$ $P(F|C)$ $P(D)$ $P(G|D)$ $P(I|F, G)$

$$\text{somme sur } A \Rightarrow P(C) = \sum_A P(A)P(C|A)$$

Shafer-Shenoy graphique (2/6)

Séquence d'élimination

A C D F G

$$P(C, D, F, G, I) = P(C)P(F|C)P(D)P(G|D)P(I|F, G)$$

$P(A)P(C|A)$

 $P(C)$ $P(F|C)$ $P(D)$ $P(G|D)$ $P(I|F, G)$

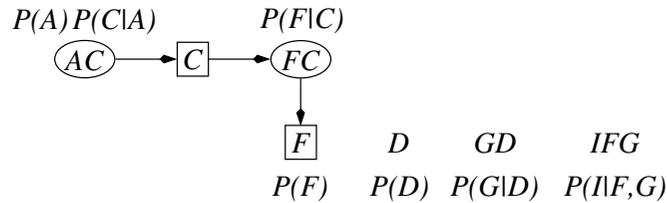
$$\text{somme sur } C \Rightarrow P(F) = \sum_C P(C)P(F|C)$$

Shafer-Shenoy graphique (3/6)

Séquence d'élimination

A C **D** F G

$$P(D, F, G, I) = P(F) P(D)P(G|D) P(I|F, G)$$



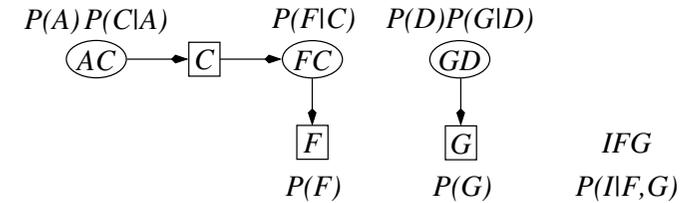
$$\text{somme sur } D \Rightarrow P(G) = \sum_D P(D)P(G|D)$$

Shafer-Shenoy graphique (4/6)

Séquence d'élimination

A C D **F** G

$$P(D, F, G, I) = P(F)P(I|F, G) P(G)$$



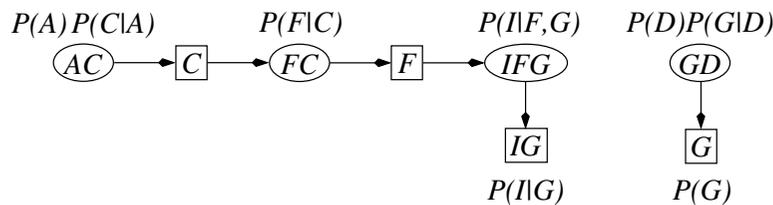
$$\text{somme sur } F \Rightarrow P(I|G) = \sum_F P(F)P(I|F, G)$$

Shafer-Shenoy graphique (5/6)

Séquence d'élimination

A C D F **G**

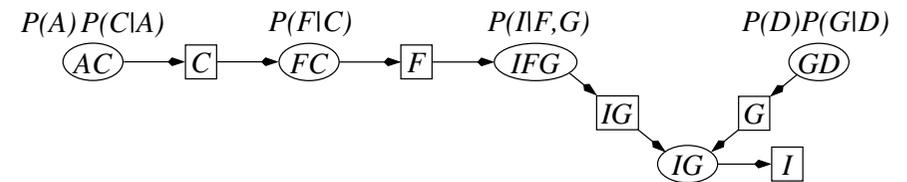
$$P(D, F, G, I) = P(I|G)P(G)$$



$$\text{somme sur } G \Rightarrow P(I) = \sum_G P(G)P(I|G)$$

Shafer-Shenoy graphique (6/6)

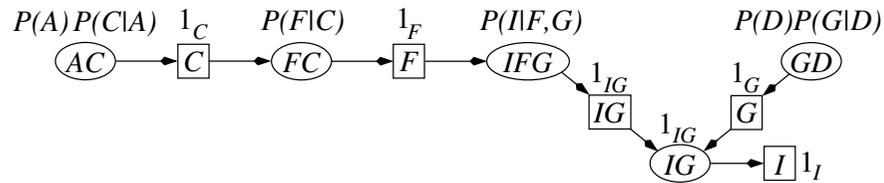
Le graphe final obtenu par Shafer-Shenoy



Algorithme de Shafer-Shenoy

- 1 Se donner une séquence d'élimination des nœuds \Rightarrow join tree,
- 2 propager les impacts dans le sens des flèches :
 - dans les ellipses (cliques), on effectue des multiplications,
 - dans les rectangles (séparateurs), on effectue des additions (projections).

Quelques remarques sur Shafer-Shenoy (1/3)

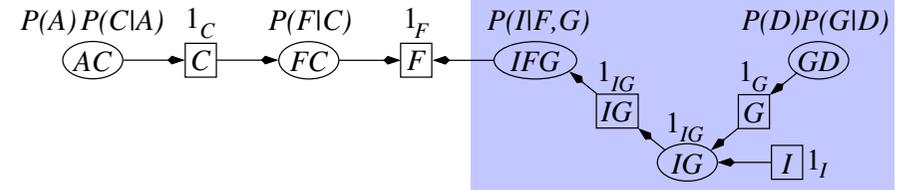


- 1 Loi jointe = produit des fonctions des cliques et des séparateurs : $P(A, C, D, F, G, I) =$

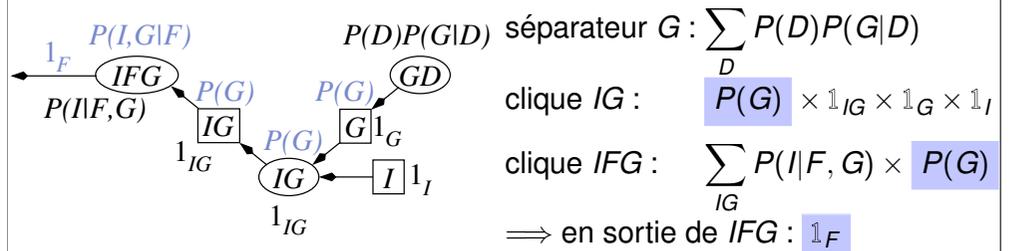
$$P(A)P(C|A)P(F|C)P(D)P(G|D)P(I|F, G).$$

- 2 Élimination récursive des cliques et séparateurs « externes » \implies le produit des fonctions des cliques et des séparateurs restants = loi jointe des variables restantes.

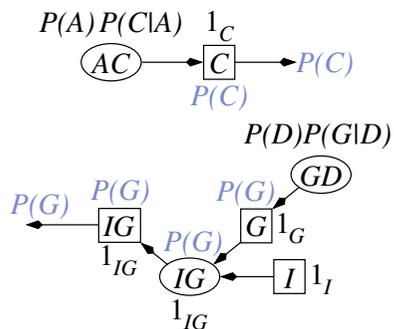
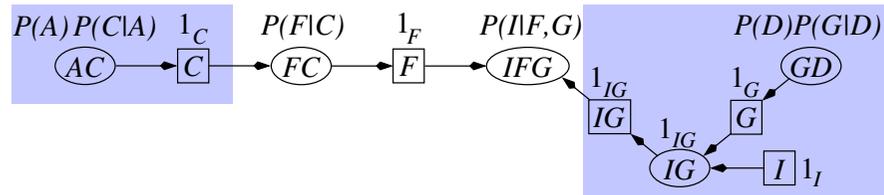
Quelques remarques sur Shafer-Shenoy (2/3)



$$P(A) \times P(C|A) \times P(F|C) \times 1_C \times 1_F = P(A, C, F).$$



Quelques remarques sur Shafer-Shenoy (3/3)



Produit des cliques et séparateurs restants :

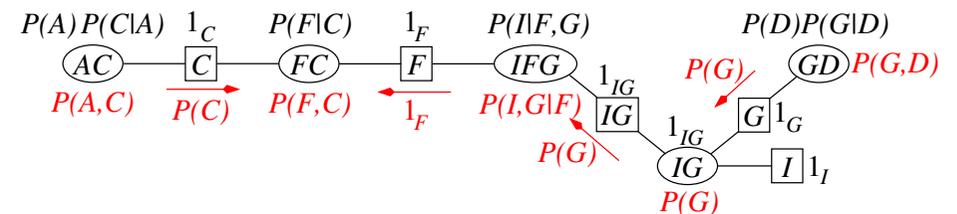
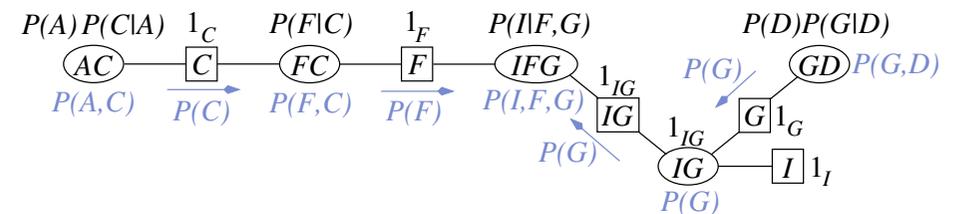
$$P(C) P(F|C) 1_F P(I|F, G) P(G)$$

$$= P(I, C, F, G)$$

Conclusion : on peut utiliser le même graphe pour calculer toutes les probabilités marginales

C'est pas le deux en un, mais le tout en deux (1/3)

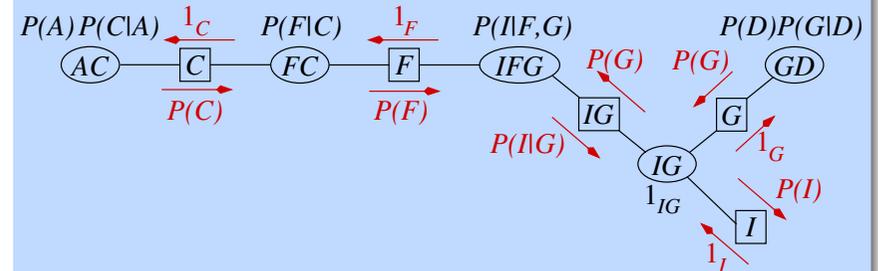
En bleu : les calculs de $P(I, F, G)$, en rouge, ceux de $P(F, C)$



Algorithme de Shafer-Shenoy

- 1 Chaque séparateur contient deux messages initialisés à 1, un en direction de chaque clique voisine.
- 2 Chaque nœud du join tree envoie des messages vers ses voisins en respectant les deux règles suivantes :
 - 1 avant d'envoyer un message vers son voisin X , le nœud Y attend que tous ses autres voisins lui aient envoyé leur message.
 - 2 le message d'un nœud Y vers son voisin X est le produit de tous les messages reçus par Y , à l'exception de celui envoyé par X , et de la table stockée par Y , le tout marginalisé sur X (c'est-à-dire sommé sur les variables de $Y \setminus X$).

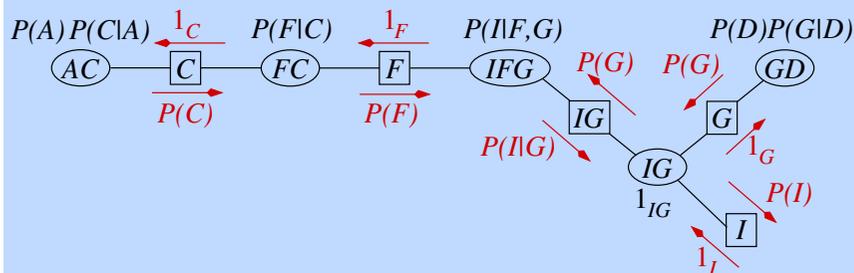
Algorithme de Shafer-Shenoy



À la fin de l'algorithme, pour tout nœud X , le produit de la table stockée en X par l'ensemble des messages envoyés à X est la probabilité jointe des variables de X .

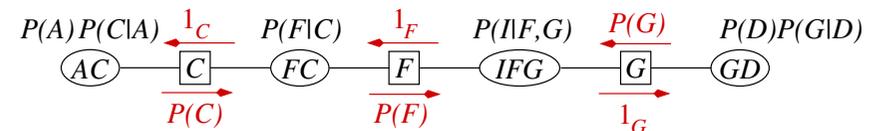
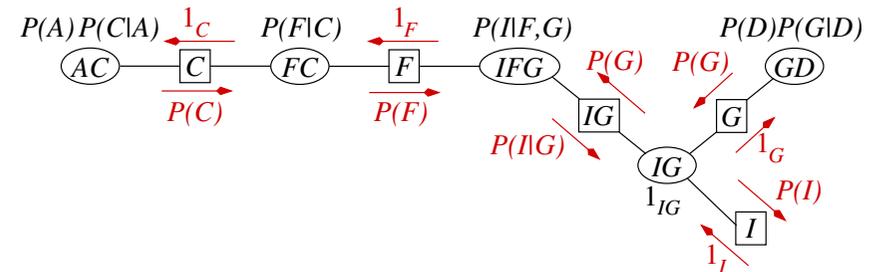
Shafer-Shenoy : ce qu'il faut retenir

Algorithme de Shafer-Shenoy



- cliques = ellipses, séparateurs = rectangles
- algorithme par envoi de messages
- opérateurs = + sur les séparateurs, × sur les cliques

Les arbres de jonction



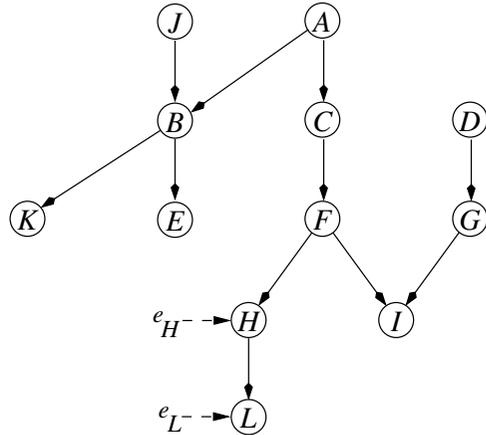
arbre de jonction : suppression des cliques incluses dans d'autres cliques

Soyons observateur : les probabilités a posteriori

Nous observons des informations e_H sur H et e_L sur L .

On veut connaître $P(I|e_H, e_L)$

⇒ on va calculer $P(I, e_H, e_L)$ car c'est plus simple



Quelles sont ces informations ?

Teneur des informations

informations = observations :

$e_L = \ll L \text{ ne peut plus prendre les valeurs } l_1 \text{ et } l_4 \gg$

Entrée de ces observations : $P(e_L|L)$

Vous avez dit calcul de $P(e_L|L)$? (1/2)

observation : $e_L = \ll \text{Le capteur m'indique que } L \text{ ne peut plus prendre les valeurs } l_1 \text{ et } l_4 \gg$

$$P(e_L|L) = \begin{array}{|c|} \hline 0 \\ \hline 1 \\ \hline 1 \\ \hline 0 \\ \hline \end{array} \begin{array}{l} l_1 \\ l_2 \\ l_3 \\ l_4 \end{array}$$

⚠ dimension de $P(e_L|L) = |L|$

Vous avez dit calcul de $P(e_L|L)$? (2/2)

observation : $e_L = \ll \text{Le capteur m'indique que } L \text{ ne peut plus prendre les valeurs } l_1 \text{ et } l_4. \text{ Mais je n'ai pas totalement confiance en ce capteur. Je pense qu'il y a 10\% de chances pour que le capteur se trompe au sujet de } l_1 \text{ et 20\% au sujet au sujet de } l_3. \gg$

$$P(e_L|L) = \begin{array}{|c|} \hline 0.1 \\ \hline 1 \\ \hline 0.8 \\ \hline 0 \\ \hline \end{array} \begin{array}{l} l_1 \\ l_2 \\ l_3 \\ l_4 \end{array}$$

Hypothèses et conséquences (1/4)

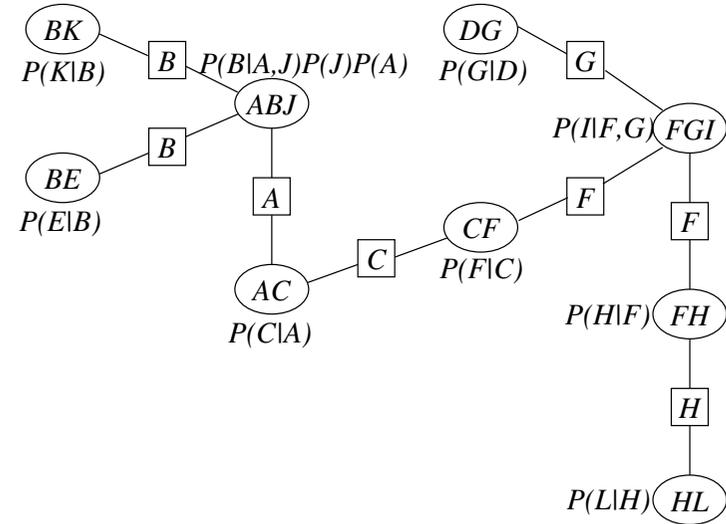
Hypothèse

Toute information e_X sur un nœud X est indépendante du reste du réseau bayésien conditionnellement à X .

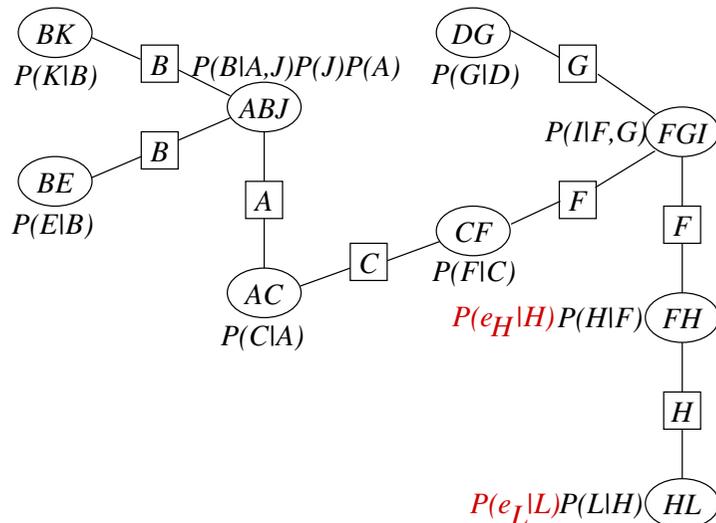
Conséquence

$$\begin{aligned}
 P(A, B, C, D, E, F, G, H, I, J, K, L, e_H, e_L) &= \\
 &P(e_H|A, B, C, D, E, F, G, H, I, J, K, L, e_L) \times \\
 &P(e_L|A, B, C, D, E, F, G, H, I, J, K, L) \times \\
 &P(A, B, C, D, E, F, G, H, I, J, K, L) \\
 &= P(e_H|H)P(e_L|L)P(A, B, C, D, E, F, G, H, I, J, K, L)
 \end{aligned}$$

Hypothèses et conséquences (2/4)



Hypothèses et conséquences (3/4)



Hypothèses et conséquences (4/4)

L'algorithme de Shafer-Shenoy permet donc de calculer dans la clique FGI : $P(F, G, I, e_H, e_L)$

$$\Rightarrow P(I, e_H, e_L) = \sum_{F, G} P(F, G, I, e_H, e_L)$$

$$\Rightarrow P(I|e_H, e_L) = \frac{P(I, e_H, e_L)}{P(e_H, e_L)}$$

$$\text{Or } P(e_H, e_L) = \sum_I P(I, e_H, e_L)$$

$$\text{Donc } P(I|e_H, e_L) = \frac{P(I, e_H, e_L)}{\sum_I P(I, e_H, e_L)}$$

Algorithme de Shafer-Shenoy

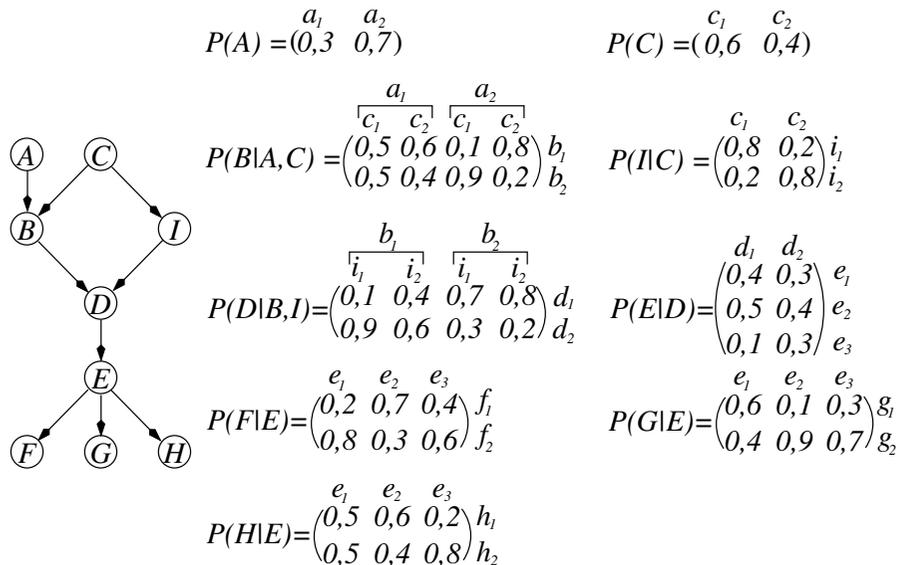
Pour calculer une proba *a posteriori* $P(Y|e)$:

- 1 construire l'arbre de jonction
- 2 insérer les probas conditionnelles du réseau bayésien dans les cliques
- 3 insérer des tables contenant uniquement des 1 dans les séparateurs
- 4 pour chaque information e_X , calculer $P(e_X|X)$ et insérer cette proba dans une clique contenant X
- 5 envoyer les messages dans l'arbre de jonction
- 6 choisir une clique contenant Y , faire le produit de sa table de proba par tous les messages qui lui ont été envoyés, puis sommer sur toutes les variables $\neq Y \implies P(Y, e)$
- 7 normaliser $P(Y, e) \implies P(Y|e)$

Quelques références

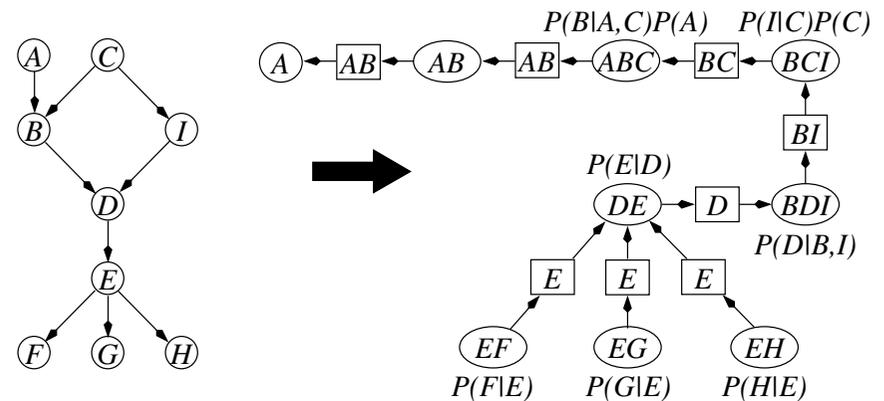
- 1 **G. Shafer (1996)** *Probabilistic expert systems*, Society for Industrial and Applied Mathematics.
- 2 **P.P. Shenoy, G. Shafer (1990)** *Axioms for probability and belief-function propagation*, Uncertainty in Artificial Intelligence 4, pp.169–198.
- 3 **P.P. Shenoy (1997)** *Binary join trees for computing marginals in the Shenoy-Shafer architecture*, International Journal of Approximate Reasoning 17, pp.1–25.
- 4 **V. Lepar, P.P. Shenoy (1998)** *A Comparison of Lauritzen-Spiegelhalter, Hugin and Shenoy-Shafer Architectures for Computing Marginals of Probability Distributions*, Proceedings of UAI-98, pp.328–337.

Exemple à l'usage des étudiants studieux (1/9)



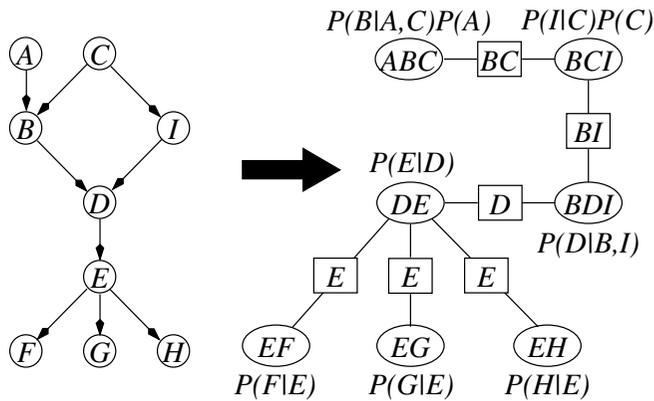
Exemple à l'usage des étudiants studieux (2/9)

Séquence d'élimination : F, H, G, E, D, I, C, B, A

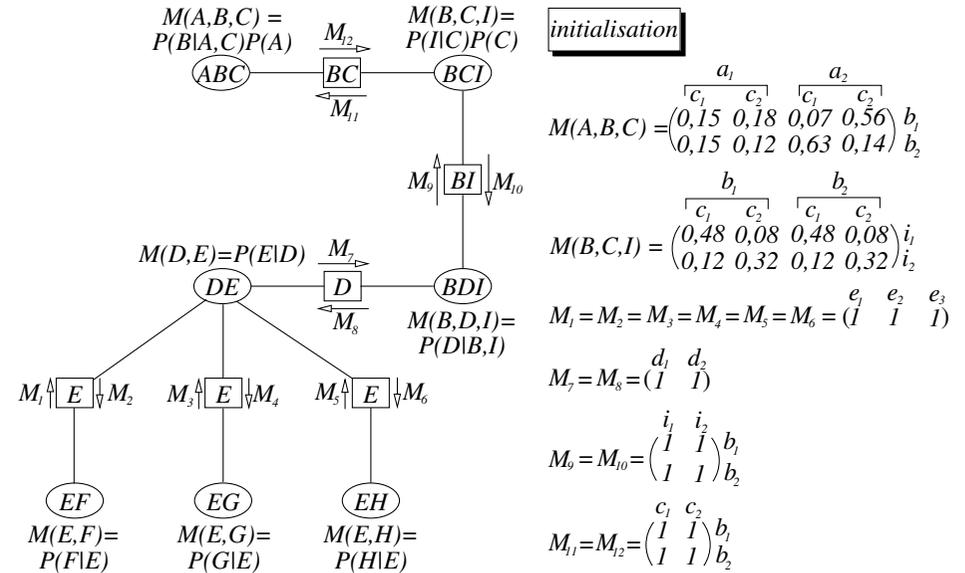


Exemple à l'usage des étudiants studieux (3/9)

Séquence d'élimination : F, H, G, E, D, I, C, B, A



Exemple à l'usage des étudiants studieux (4/9)



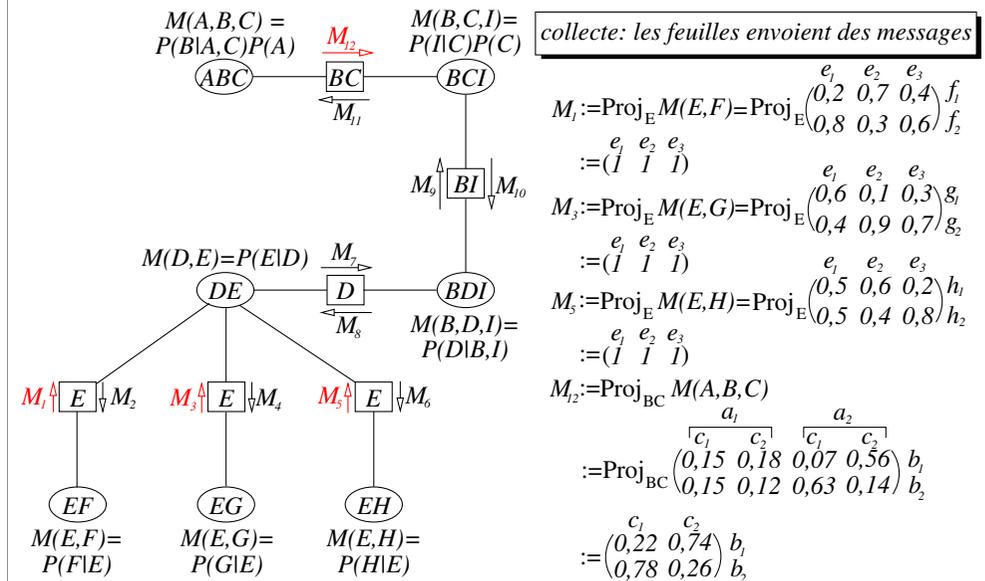
Rappel : dissection du produit de deux probabilités

$$M(A,B,C) = \begin{pmatrix} \begin{matrix} a_1 & a_2 \\ c_1 & c_2 \end{matrix} \\ \begin{matrix} 0,15 & 0,18 & 0,07 & 0,56 \\ 0,15 & 0,12 & 0,63 & 0,14 \end{matrix} \end{pmatrix} \begin{matrix} b_1 \\ b_2 \end{matrix} = \begin{pmatrix} \begin{matrix} a_1 & a_2 \\ c_1 & c_2 \end{matrix} \\ \begin{matrix} 0,5 & 0,6 & 0,1 & 0,8 \\ 0,5 & 0,4 & 0,9 & 0,2 \end{matrix} \end{pmatrix} \begin{matrix} b_1 \\ b_2 \end{matrix} \times \begin{pmatrix} a_1 & a_2 \\ 0,3 & 0,7 \end{pmatrix} \begin{matrix} b_1 \\ b_2 \end{matrix}$$

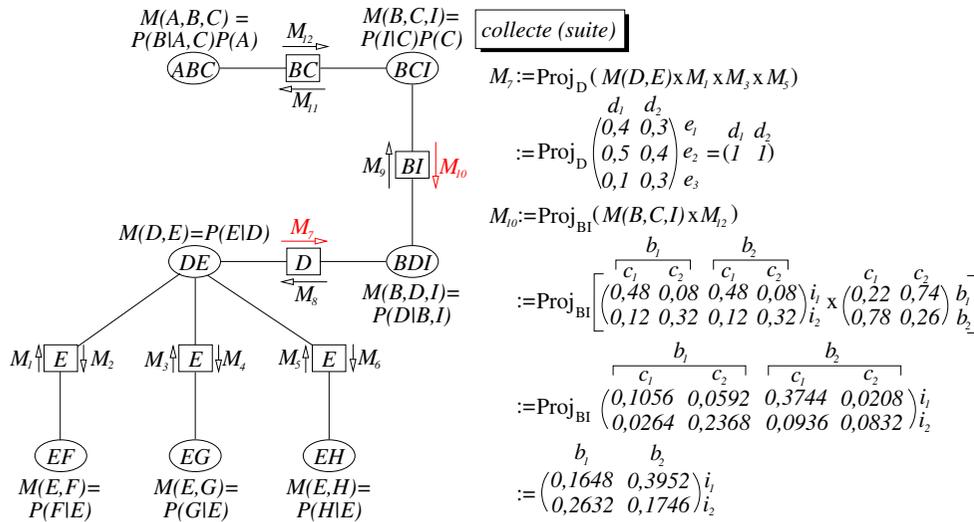
$P(B|A,C)$ $P(A)$

$$M(B,C,I) = \begin{pmatrix} \begin{matrix} b_1 & b_2 \\ c_1 & c_2 \end{matrix} \\ \begin{matrix} 0,48 & 0,08 & 0,48 & 0,08 \\ 0,12 & 0,32 & 0,12 & 0,32 \end{matrix} \end{pmatrix} \begin{matrix} i_1 \\ i_2 \end{matrix} = \begin{pmatrix} \begin{matrix} P(I|C) \\ c_1 & c_2 \end{matrix} \\ \begin{matrix} 0,8 & 0,2 \\ 0,2 & 0,8 \end{matrix} \end{pmatrix} \begin{matrix} i_1 \\ i_2 \end{matrix} \times \begin{pmatrix} c_1 & c_2 \\ 0,6 & 0,4 \end{pmatrix} \begin{matrix} b_1 \\ b_2 \end{matrix}$$

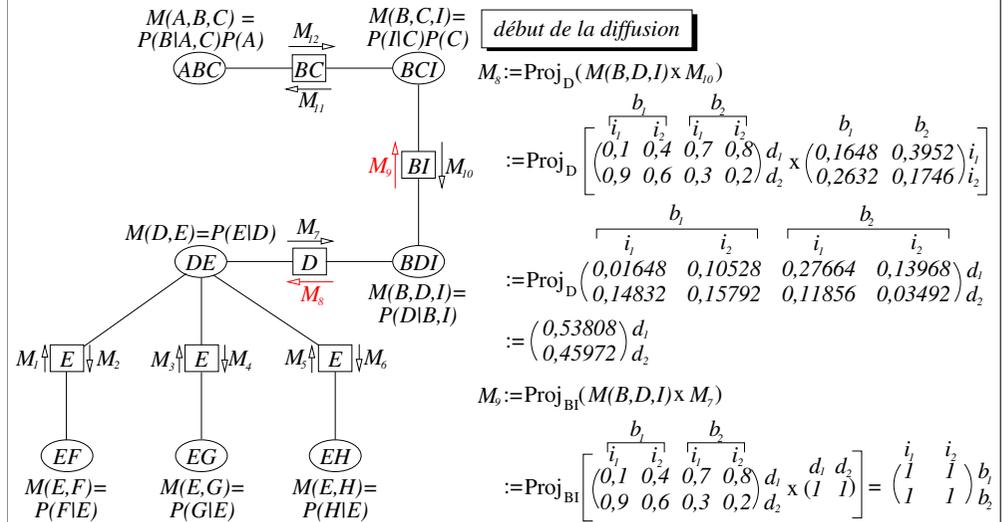
Exemple à l'usage des étudiants studieux (5/9)



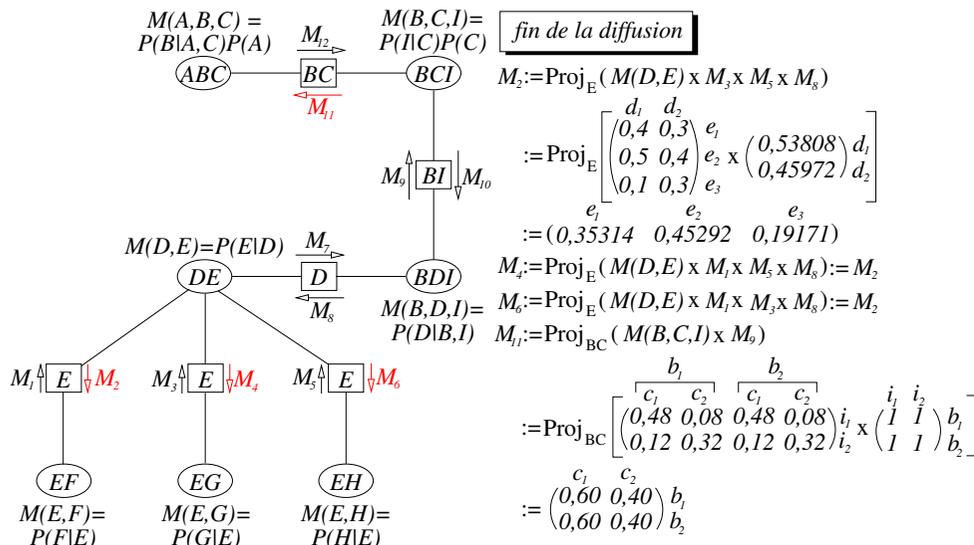
Exemple à l'usage des étudiants studieux (6/9)



Exemple à l'usage des étudiants studieux (7/9)



Exemple à l'usage des étudiants studieux (8/9)



Exemple à l'usage des étudiants studieux (9/9)

$$M_{11} \times M(A, B, C) = \begin{pmatrix} c_1 & c_2 \\ 0,60 & 0,40 \\ 0,60 & 0,40 \end{pmatrix} \begin{matrix} b_1 \\ b_2 \end{matrix} \times \begin{pmatrix} a_1 & a_2 \\ c_1 & c_2 & c_1 & c_2 \\ 0,15 & 0,18 & 0,07 & 0,56 \\ 0,15 & 0,12 & 0,63 & 0,14 \end{pmatrix} \begin{matrix} b_1 \\ b_2 \end{matrix} \\
 = \begin{pmatrix} a_1 & a_2 \\ c_1 & c_2 & c_1 & c_2 \\ 0,090 & 0,072 & 0,042 & 0,224 \\ 0,090 & 0,048 & 0,378 & 0,056 \end{pmatrix} \begin{matrix} b_1 \\ b_2 \end{matrix}$$

- 1 Petit exercice de calcul mental : calculez la projection de la matrice ci-dessus sur BC .
- 2 Petit exercice de déduction : à quoi correspond cette matrice ?
- 3 Ultime exercice à l'usage de l'élite (et des biens nantis) : calculez le produit $M_{11} \times M_{12}$.
- 4 Un dernier pour la route : dites « bizarre, bizarre, comme c'est bizarre », et expliquez pourquoi c'est bizarre.

2 Existe-t-il d'autres algorithmes d'inférence ?

De Shafer-Shenoy à Lazy propagation



si $P(A, B, C, D, E) = P(A)P(B)P(C|A, B)P(D)P(E|C, D)$

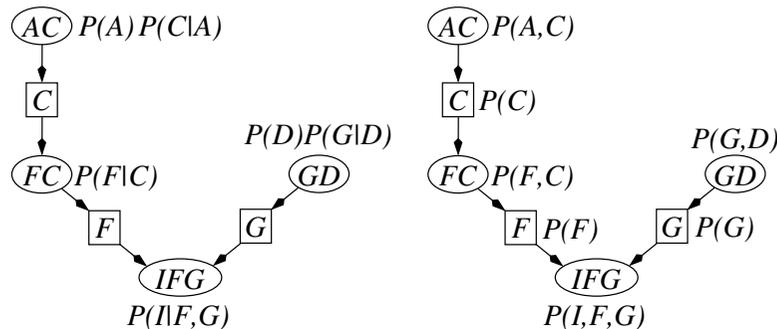
$$\begin{aligned} \text{alors } P(B, C, D, E) &= \sum_A P(A)P(B)P(C|A, B)P(D)P(E|C, D) \\ &= \left(\sum_A P(A)P(C|A, B) \right) P(B)P(D)P(E|C, D) \end{aligned}$$

⇒ on a intérêt à ne pas effectuer les produits avant les sommes

Lazy propagation

Principe : garder les produits sous forme de listes et n'effectuer les multiplications que lorsque c'est nécessaire.

De Shafer-Shenoy à Jensen



Shafer-Shenoy : élimination de $A \Rightarrow P(C, e_A) = \sum_A P(A, e_A)P(C|A)$

élimination de $F \Rightarrow P(F, C, e_A) = P(F|C)P(C, e_A)$

Jensen : élimination de $F \Rightarrow P(F, C, e_A) = \frac{P(F, C)}{P(C)}P(C, e_A)$

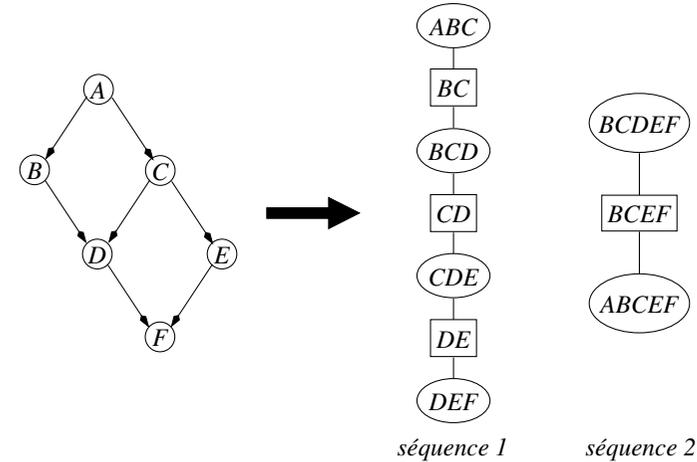
Petit guide sur Jensen et Lazy Propagation

Quelques références

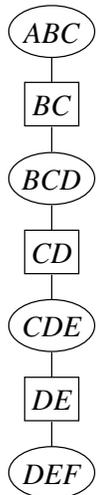
- 1 **S.L. Lauritzen, D.J. Spiegelhalter (1988)** *Local computations with probabilities on graphical structures and their application to expert systems(with discussion)*, Journal of the Royal Statistical Society, *Series B*, 50, pp.157–224.
- 2 **F.V. Jensen, S.L. Lauritzen, K.G. Olesen (1990)** *Bayesian Updating in Causal Probabilistic Networks by Local Computations*, Comp. Stat. Quarterly, 4, pp.269–282.
- 3 **A.L. Madsen, F.V. Jensen (1998)** *Lazy Propagation in Junction Trees*, Proceedings d'UAI-98.
- 4 **A.L. Madsen, F.V. Jensen (1999)** *Lazy Propagation : A Junction Tree Inference Algorithm Based on Lazy Evaluation*, Artificial Intelligence, 113, pp.203–245.

3 Comment construire l'arbre de jonction ou la triangulation par l'exemple

Séquence 1 : A, B, C, F, D, E Séquence 2 : D, C, A, E, B, F



De la propriété d'intersection courante



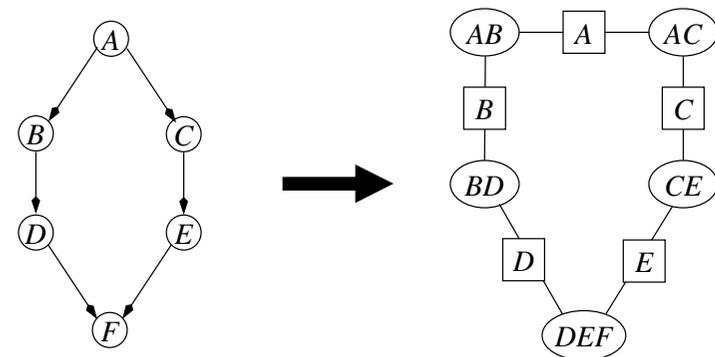
Propriété d'intersection courante

Soient C_1 et C_2 deux cliques quelconques de l'arbre de jonction et soit $S = C_1 \cap C_2 \neq \emptyset$. Alors sur toute chaîne reliant C_1 et C_2 , les cliques et séparateurs contiennent S

Théorème

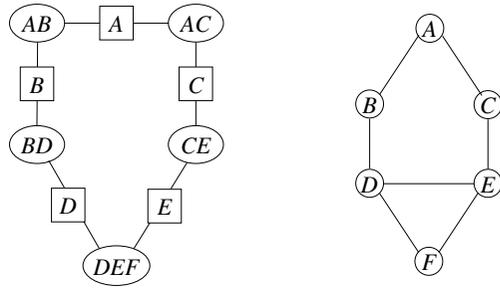
L'algorithme de Shafer-Shenoy fonctionne avec n'importe quel graphe sans cycle vérifiant la propriété d'intersection courante (ce que l'on appelle un *join tree*)

Un graphe de jonction avec cycles



Si l'on n'y prend garde, des cycles peuvent exister bien que la propriété d'intersection courante soit vérifiée

Graphe de jonction et triangulation (1/2)

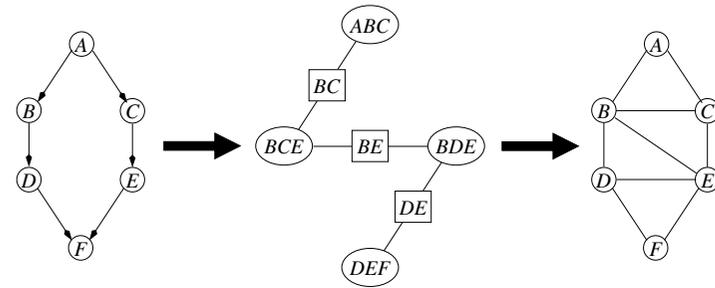


Triangulation

Un graphe non orienté est triangulé si et seulement si, pour tout cycle de longueur 4 ou plus, il existe une corde, c'est-à-dire une arête reliant deux nœuds non consécutifs du cycle

Exemple : le graphe ci-dessus n'est pas triangulé car le cycle A, B, D, E, C, A ne comporte pas de corde

Graphe de jonction et triangulation (2/2)



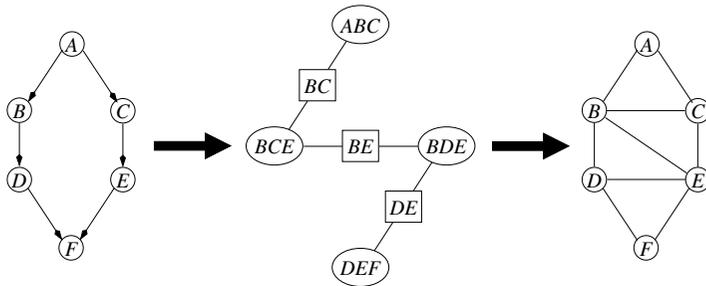
Proposition

il y a équivalence entre les deux assertions :

- 1 Le graphe de jonction est acyclique
- 2 Le graphe non orienté correspondant est triangulé

⇒ pour trouver un « bon » arbre de jonction, il faut trouver une « bonne » triangulation

Un peu de morale, ça ne fait pas de mal



Moralisation

relier tous les parents d'un même nœud, puis supprimer les orientations ⇒ le graphe moral.

⇒ les cliques pourront contenir l'ensemble des probabilités conditionnelles de la décomposition de la loi jointe

Recherche des triangulations optimales (1/2)

Proposition (Rose 1970)

Un graphe non orienté est triangulé si et seulement si l'application des deux règles suivantes permet d'éliminer tous les nœuds X_i du graphe sans rajouter une seule arête :

- 1 on rajoute des arêtes entre tous les voisins du nœud X_i que l'on veut éliminer (on forme une clique)
- 2 on supprime X_i ainsi que les arêtes qui lui sont adjacentes du graphe

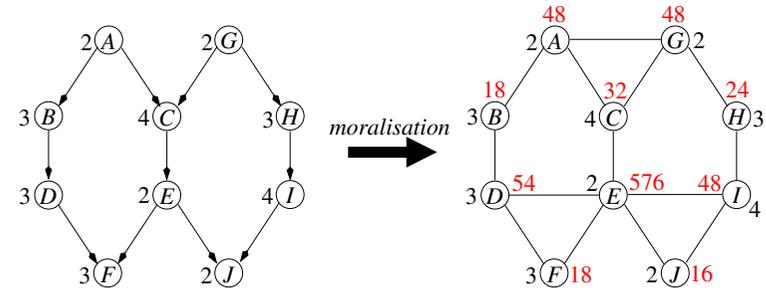
⇒ pour créer un join tree, il suffit de partir d'un graphe non orienté et d'appliquer, avec une certaine séquence d'élimination, les deux points ci-dessus

Mellouli (87) : Tout join tree « optimal » peut être construit à partir d'une séquence d'élimination

Recherche des triangulations optimales (2/2)

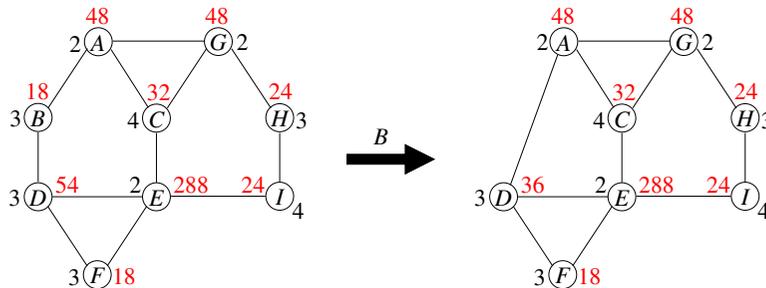
- **Arnborg et al. (87)** : trouver la triangulation optimale est NP-difficile \implies essayer de trouver des heuristiques
- **Kjærulff (90)** : un algorithme glouton rapide et efficace :
Soit un graphe non orienté (moral) $G = (X, E)$, $X = \{X_1, \dots, X_n\}$
 - 1 Associer à chaque X_i un « poids » égal au produit des modalités de X_i et de ses voisins
 - 2 éliminer le nœud X_i dont le poids est minimal (i.e., relier tous ses voisins de manière à former une clique C_i puis éliminer X_i et ses arêtes adjacentes)
 - 3 mettre à jour les poids des nœuds restants \implies les C_i sont les cliques (ellipses) du join tree
- **van den Eijkhof & Bodlaender (2002)** : “safe reductions”
 \implies élimination de variables avec garantie d’optimalité
- Autres algorithmes : Becker & Geiger (96) ; Shoiket & Geiger (87)

Exemple de création de join tree (1/5)



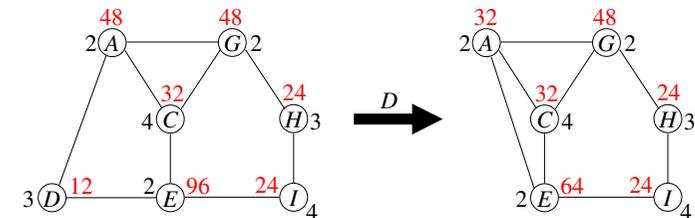
Variable à éliminer : $J \implies$ clique EIJ

Exemple de création de join tree (2/5)



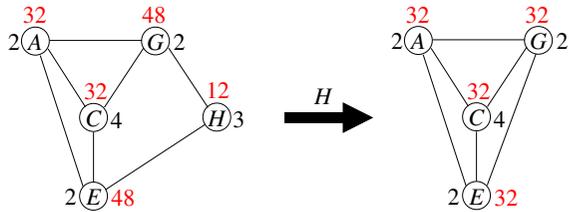
première variable à éliminer : $B \implies$ clique ABD
deuxième variable à éliminer : $F \implies$ clique DEF

Exemple de création de join tree (3/5)



première variable à éliminer : $D \implies$ clique ADE
deuxième variable à éliminer : $I \implies$ clique EHI

Exemple de création de join tree (4/5)



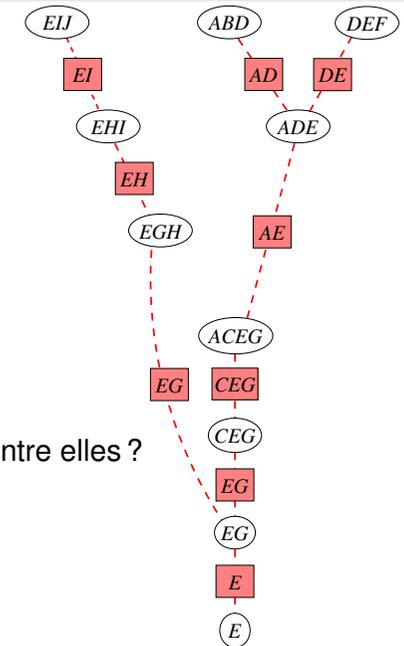
- première variable à éliminer : $H \Rightarrow$ clique EGH
- deuxième variable à éliminer : $A \Rightarrow$ clique $ACEG$
- puis les autres variables peuvent être éliminées dans n'importe quel ordre puisqu'elles appartiennent toutes à la même clique :
 - $C \Rightarrow$ clique CEG
 - $G \Rightarrow$ clique EG
 - $E \Rightarrow$ clique E

Exemple de création de join tree (5/5)

Ensemble des cliques selon leur ordre de création (avec la variable dont l'élimination a créé la clique) :

EIJ (J), ABD (B), DEF (F), ADE (D),
 EHI (I), EGH (H), $ACEG$ (A),
 CEG (C), EG (G), E (E)

Problème : comment relier les cliques entre elles ?



Des cliques vers l'arbre d'élimination (1/2)

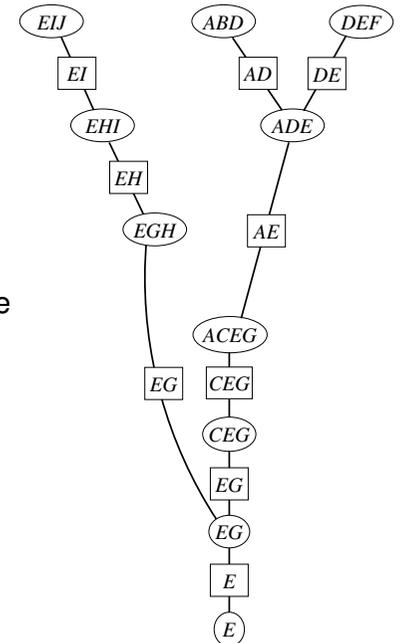
Définition de l'arbre d'élimination

- Soit $\sigma : \{1, \dots, n\} \mapsto \{1, \dots, n\}$ la permutation telle que les variables X_i sont éliminées dans l'ordre $X_{\sigma(1)}, \dots, X_{\sigma(n)}$
- Pour tout i , soit $D_{\sigma(i)}$ la clique créée au moment où $X_{\sigma(i)}$ est éliminée
- Arbre d'élimination : graphe $\mathcal{G} = (\mathcal{D}, \mathcal{E})$, où :
 - $\mathcal{D} = \{D_{\sigma(i)} : i \in \{1, \dots, n\}\}$,
 - $\mathcal{E} = \{(D_{\sigma(i)}, D_{\sigma(j)}) : 1 \leq i < n, j = \min\{k \neq i : X_{\sigma(k)} \in D_{\sigma(i)}\}\}$

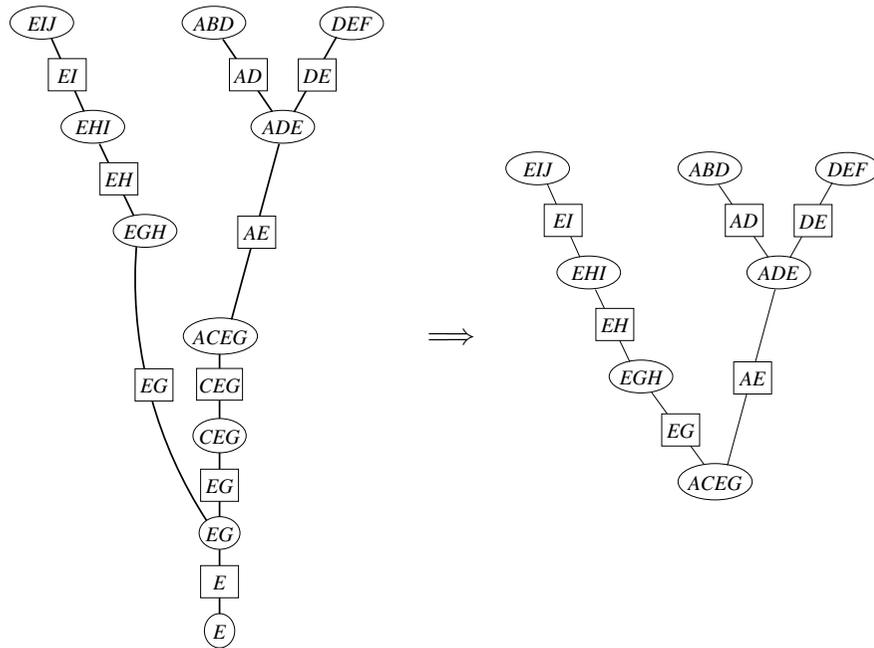
\Rightarrow Si l'on trie les nœuds X_i à l'intérieur des cliques selon leur ordre d'élimination, alors :
 on relie $D_{\sigma(i)} = \{X_{\sigma(i)}, X_{\sigma(j)}, \dots\}$ à $D_{\sigma(j)}$.

Des cliques vers l'arbre d'élimination (2/2)

- Arbre d'élimination : $\mathcal{G} = (\mathcal{D}, \mathcal{E})$, où :
 - $\mathcal{D} = \{D_{\sigma(i)} : i \in \{1, \dots, n\}\}$,
 - $\mathcal{E} = \{(D_{\sigma(i)}, D_{\sigma(j)}) : 1 \leq i < n, j = \min\{k \neq i : X_{\sigma(k)} \in D_{\sigma(i)}\}\}$
- Ensemble des cliques selon leur ordre de création (avec la variable dont l'élimination a créé la clique) :
 EIJ (J), ABD (B), DEF (F), ADE (D),
 EHI (I), EGH (H), $ACEG$ (A),
 CEG (C), EG (G), E (E)



De l'arbre d'élimination vers l'arbre de jonction (1/2)



Propriétés de l'arbre d'élimination

Propriétés

$$\mathcal{D} = \{D_{\sigma(i)} : i \in \{1, \dots, n\}\},$$

$$\mathcal{E} = \{(D_{\sigma(i)}, D_{\sigma(j)}) : 1 \leq i < n, j = \min\{k \neq i : X_{\sigma(k)} \in D_{\sigma(i)}\}\}$$

- 1 L'arbre d'élimination est un arbre
- 2 Il vérifie la propriété d'intersection courante
- 3 Soit $D_{\sigma(j)}$ un enfant de $D_{\sigma(i)}$, alors $|D_{\sigma(j)}| \geq |D_{\sigma(i)}| - 1$
- 4 Soient $D_{\sigma(i)}$ et $D_{\sigma(j)}$ les parents de $D_{\sigma(k)}$, alors $D_{\sigma(i)} \not\subset D_{\sigma(j)}$ et $D_{\sigma(j)} \not\subset D_{\sigma(i)}$
- 5 Soit $D_{\sigma(j)}$ un enfant de $D_{\sigma(i)}$, alors $D_{\sigma(j)} \subset D_{\sigma(i)} \iff |D_{\sigma(j)}| = |D_{\sigma(i)}| - 1$
- 6 Soit $D_{\sigma(j)}$ un enfant de $D_{\sigma(i)}$ tel que $D_{\sigma(j)} \not\subset D_{\sigma(i)}$, alors il n'existe pas d'ancêtre $D_{\sigma(k)}$ de $D_{\sigma(i)}$ tel que $D_{\sigma(j)} \subset D_{\sigma(k)}$

De l'arbre d'élimination vers l'arbre de jonction (2/2)

Algorithme pour obtenir un arbre de jonction

- 01 créer l'arbre d'élimination $\mathcal{G} = (\mathcal{D}, \mathcal{E})$
- 02 marquer à **false** tous les arcs de \mathcal{E}
- 03 **pour** i variant de n à 1 **faire**
- 04 **si** il existe $D_{\sigma(j)}$ parent de $D_{\sigma(i)}$ tel que l'arc $(D_{\sigma(j)}, D_{\sigma(i)})$ est non marqué et $|D_{\sigma(i)}| = |D_{\sigma(j)}| - 1$ **alors**
- 05 **pour** tous les autres parents $D_{\sigma(k)}$ de $D_{\sigma(i)}$ **faire**
- 06 créer dans \mathcal{G} un arc $(D_{\sigma(k)}, D_{\sigma(j)})$
- 07 marquer cet arc à **true**
- 08 **fait**
- 09 **si** $D_{\sigma(i)}$ a un enfant $D_{\sigma(k)}$ **alors**
- 10 créer dans \mathcal{G} un arc $(D_{\sigma(j)}, D_{\sigma(k)})$
- 11 **fin**
- 12 supprimer $D_{\sigma(i)}$ ainsi que ses arcs adjacents
- 13 **fait**

A la fin de l'algorithme ci-dessus, \mathcal{G} est un arbre de jonction.

Améliorations de l'algorithme d'élimination

- Au lieu de choisir le nœud à éliminer en fonction du poids, choisir, quand c'est possible, un nœud appartenant à une seule clique (« simplicial rule », bodlaender (02)) ;
- Sous certaines contraintes, choisir un nœud presque simplicial (il manque une seule arête pour former une clique) ;
- Autres règles de réduction optimales (Buddies rule, Extended cube rule...);
- Suppression des arêtes de triangulation superflues (cf. Kjærulff (90)) — nécessite de recalculer la séquence d'élimination (par exemple par maximum cardinality search) ;
- Optimisation de l'arbre de jonction par modification des adjacences (cf. Jensen & Jensen (94)).

Quelques références

- **Kjærulff, U (1990)** *Triangulation of graphs – Algorithms giving small total state space*, technical report.
- **Kjærulff, U (1991)** *Optimal decomposition of probabilistic networks by simulated annealing*, Statistics and Computing, Vol 2, pp7-17.
- **Becker, A & Geiger, D (1996)** *A sufficiently fast algorithm for finding close to optimal junction trees*, Proceedings d'UAI-96.
- **van den Eijkhof, F & Bodlaender A (2002)** *Safe reduction rules for weighted treewidth*, Proceedings of the 28th International Workshop on Graph-Theoretic Concepts in Computer Science, Lecture Notes in Computer Science, vol 2573, pp176–185.

Quelques références

- **Jensen, F.V. & Jensen, F. (1994)** *Optimal junction trees* Proceedings d'UAI-94.
- **Shoikhet, K & Geiger, D (1997)** *Finding optimal triangulations via minimal vertex separators*, Proceedings de AAAI-97.
- **Leimer, H.-G. (1993)** *Optimal decomposition by clique separators*, Discrete Mathematics, vol 113, pp99-123.
- **Olesen, K & Madsen, A (1999)** *Maximal prime decomposition of Bayesian networks*, technical report.
- **Flores, J & Gámez, J & Olesen, K (2003)** *Incremental compilation of Bayesian networks*, Proceedings d'UAI-03.