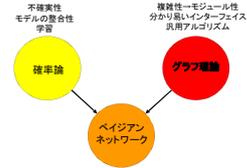


情報意味論 (9) ベイジアンネットワーク

慶應義塾大学工学部
櫻井 彰人

どこから生まれてきたか？

- 実問題の共通課題：
 - 不確実性 ← 確率的枠組み ← 確率変数を用いよう
 - 複雑性 ← すっきりと表現しよう



確率変数を用いて簡潔に

- 原理的にできそう：
全変数の結合確率で表現
しかし、naïve Bayes の時と同様に
- 「全変数の結合確率」ではパラメータが多すぎ
かといっても、naïve Bayes は単純化しすぎ
- 「全変数の結合確率」と「naïve Bayes」の間
はないか？
- Bayesian network は一つの答え

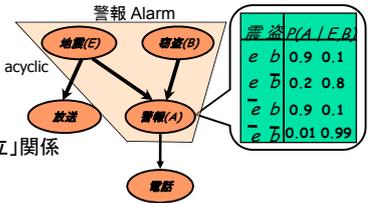
BNとは何か？

条件付確率を用いた、結合確率のコンパクトな表現

定性的要素：

有向無閉路グラフ directed acyclic graph (DAG)

- ノード - 確率変数.
- エッジ - 非「条件付独立」関係



あわせて：

ある確率分布の因数分解(? 確率分布の積に分解)

定量的要素：
条件付確率分布の集まり

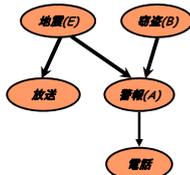
コンパクトな表現

完全な結合の表現



$$p(e, b, r, a, t) = p(e)p(b|e)p(a|e, b)p(r|e, b, a)p(t|e, b, a, r)$$

コンパクトな表現



$$p(e, b, r, a, t) = p(e)p(b)p(a|e, b)p(r|e)p(t|a)$$

条件付き独立性

- 確率変数 x と z が y を条件として条件付き独立であるとは、

$$p(x, z|y) = p(x|y)p(z|y)$$

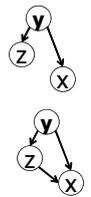
しばしば、 $x \perp\!\!\!\perp z|y$ と書く

- 条件付き確率の定義から

$$p(x, z|y) = p(x|z, y)p(z|y)$$

- 従って、 $x \perp\!\!\!\perp z|y$ if and only if

$$p(x|y) = p(x|z, y)$$



グラフカルモデル (数値)

なぜ役立つか？

- グラフ構造があるので
 - 知識をモジュール化して表現できる
 - 推論・学習に、局所的かつ分散的アルゴリズムが使える
 - 直感的な (場合によっては因果的な) 解釈が可能
- 結合確率 $P(X_1, \dots, X_n)$ をそのまま表現するより、指数関数的に少ないパラメータで、表現可能 =>
 - 学習に必要なデータ数 (sample complexity) が少なくてすむ
 - 推論に必要な時間 (time complexity) が少なくてすむ

7

何に使うか？

- 事後確率推定
 - 証拠・現象 evidence から発生した事象 event の確率を推定
- 最も可能性が高い説明
 - 証拠・現象を説明するシナリオ
- 合理的な意思決定
 - 期待成果を最大化
 - 情報の価値

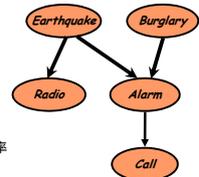


Figure from N. Friedman

応用事例

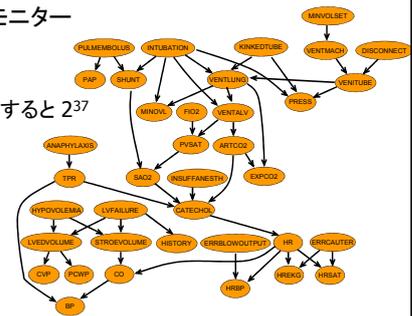
- “Microsoft’s competitive advantage lies in its expertise in Bayesian networks”
 - Bill Gates, LA Times より, 1996
- MS Answer Wizards, (printer) troubleshooters
- 医療診断
- 遺伝子系統解析
- 音声認識 (HMMs)
- 遺伝子配列分析
- Turbocodes (通信路の符号化)

9

実例: Alarm (A Logical Alarm Reduction Mechanism)

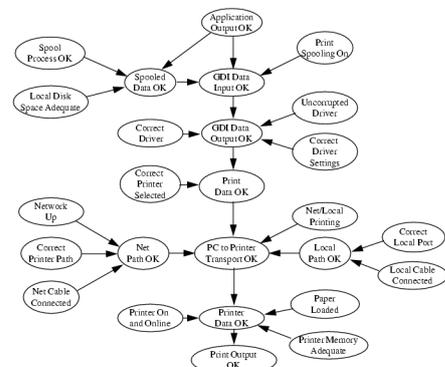
分野: ICU でのモニター

- 37 変数
 - 509 パラメータ
- ... 各変数2値とすると 2³⁷



A Logical Alarm Reduction Mechanism

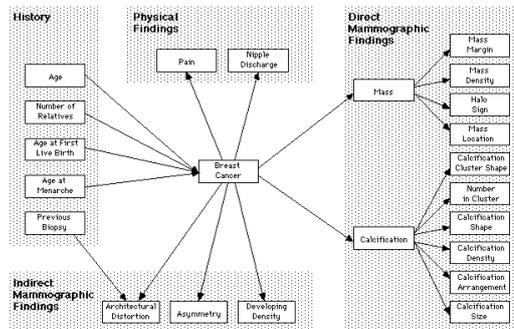
Figure from N. Friedman



Microsoft Print Troubleshooter

11

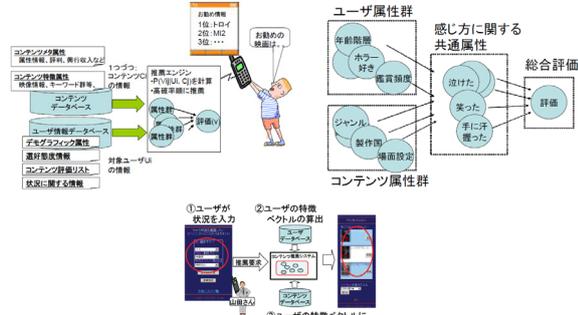
MammoNet



<http://www.mcv.edu/midas/images/mammo.model.gif>
<http://www.mcv.edu/midas/mammo.html>

12

状況に応じた映画推薦



13

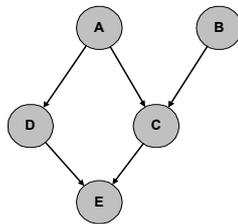
確率の変形規則...

- ベイズ規則: $\Pr(A, B) = \Pr(A|B) \cdot \Pr(B) = \Pr(B|A) \cdot \Pr(A)$
- 独立性 $A \perp B$ iff: $\Pr(A|B) = \Pr(A)$
 $\Pr(B|A) = \Pr(B)$
 $\Rightarrow \Pr(A, B) = \Pr(A) \cdot \Pr(B)$
- チェーン規則: $\Pr(A, B, C, D) = \Pr(A) \cdot \Pr(B, C, D|A)$
 $= \Pr(A) \cdot \Pr(B|A) \cdot \Pr(C, D|A, B)$
 $= \dots$
 $= \Pr(A) \cdot \Pr(B|A) \cdot \Pr(C|A, B) \cdot \Pr(D|A, B, C)$
- 周辺化 marginalize: $\Pr(A) = \sum_b \Pr(A, B=b)$

14

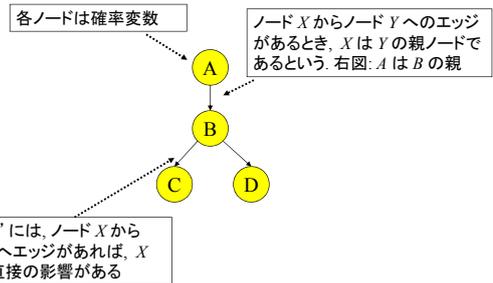
BN の形式的定義

- DAG: 有向無閉路グラフ directed acyclic graph
 - ノード: 各ノードは確率変数。変数間にはある順序がある (離散値をとる)
 - エッジ: エッジの出る側は入る側の親と呼ぶ。子ノードには、親ノードを条件とする条件付確率表 (CPT) が定義されている。各エッジは2変数間に確率的な関係がありうることを示している。正確には、「条件付独立関係がある」とは言えないことを示している。方向は、因果関係があれば、原因→結果、なければ、任意。ノード順序に矛盾しない
 - CPTs: 条件付確率表: $\Pr(X|pa(X))$
右図: $\Pr(C|A, B), \Pr(D|A), \Pr(E|C, D)$
 - 事前分布 a priori distribution: 親のないノードすべてに
右図: $\Pr(A), \Pr(B)$
- 全変数の結合確率は、上記の条件付確率の積で表される $P(X_1, \dots, X_n) = \prod P(X_i | pa(X_i))$



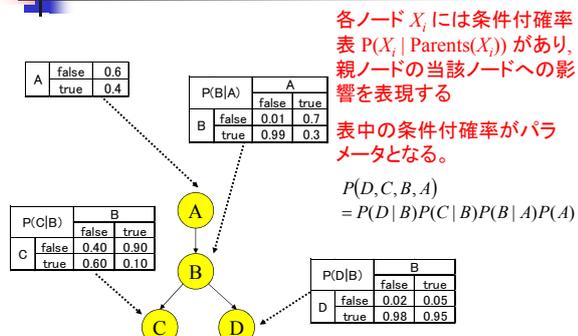
15

DAG



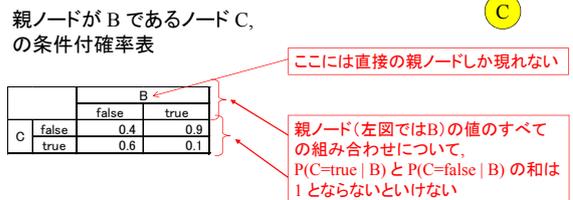
16

条件付確率表 CPT



17

条件付確率表 CPT



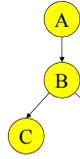
k 個の親が全てブール変数(2値変数)であれば、ブール値変数のCPTの要素数は $2^k * 2 = 2^{k+1}$ となる

18

BNの定義 (まとめると)

BNの構成要素:

1. 有向無閉路グラフ
DAG directed acyclic graph



3. 全変数の結合確率は、各ノードに付随する条件付確率の積

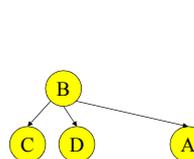
$$P(D, C, B, A) = P(D|B)P(C|B)P(B|A)P(A)$$

もし構造がなければ
 $\Pr(D|A, B, C) \cdot \Pr(C|A, B) \cdot \Pr(B|A) \cdot \Pr(A)$

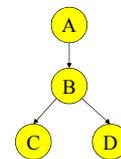
2. 各ノードに付随する条件付確率表

A	false	0.6							
	true	0.4							
			P(B A)	A					
				false	true				
B	false	0.01	0.7						
	true	0.99	0.3						
				P(D B)	B				
				false	true				
				0.02	0.05				
				true	0.98	0.95			
							P(C B)	B	
							false	true	
							0.40	0.90	
							true	0.60	0.10

補足: naïve Bayes との比較



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



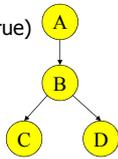
$$P(D, C, B, A) = P(D|B)P(C|B)P(B|A)P(A) = P(D|B)P(C|B)P(A, B)$$

20

計算例

先ほどの例で次の結合確率を計算する:

$$P(A = \text{true}, B = \text{true}, C = \text{true}, D = \text{true}) = P(A = \text{true}) * P(B = \text{true} | A = \text{true}) * P(C = \text{true} | B = \text{true}) * P(D = \text{true} | B = \text{true}) = (0.4) * (0.3) * (0.1) * (0.95)$$



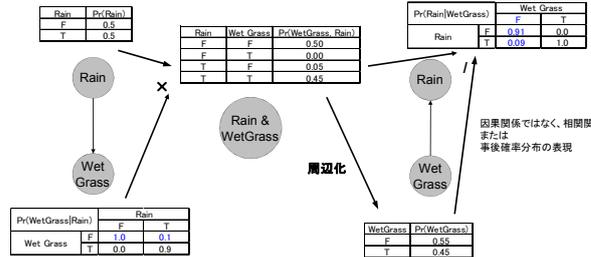
例題が簡単すぎて、あまり簡単にならないが、...

21

別の計算例

$$\Pr(R = a | WG = b) = \frac{\Pr(R = a, WG = b)}{\Pr(WG = b)}$$

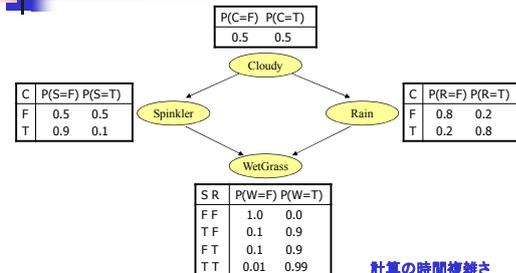
$$\Pr(WG = a, R = b) = \Pr(WG = a | R = b) \cdot \Pr(R = b)$$



$$\Pr(WG = a) = \sum_b \Pr(WG = a, R = b)$$

因果関係ではなく、相関関係または事後確率分布の表現

他の例: Water-Sprinkler



単にベイズをチェーンで:

$$\Pr(C, R, S, W) = \Pr(C) \cdot \Pr(R|C) \cdot \Pr(S|R, C) \cdot \Pr(W|R, C, S)$$

計算の時間複雑さ

$$2 \times 4 \times 8 \times 16 = 1024$$

条件付独立性を使うと:

$$\Pr(C, R, S, W) = \Pr(C) \cdot \Pr(R|C) \cdot \Pr(S|C) \cdot \Pr(W|R, S)$$

$$2 \times 4 \times 4 \times 8 = 256$$

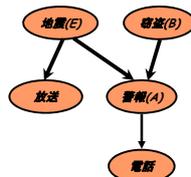
条件付独立性とBN

完全な結合の表現



$$p(e, b, a, r, t) = p(e)p(b)p(a)p(r)p(t)p(e, b, a)p(r|e, b, a)p(t|e, b, a, r)$$

コンパクトな表現



$$p(e, b, a, r, t) = p(e)p(b)p(a)p(r)p(t)p(a|e, b)p(r|e, b, a)p(t|a)$$

$$p(b) = p(b|e), b \perp\!\!\!\perp e$$

$$p(r|e, b, a) = p(r|e), b, a \perp\!\!\!\perp r|e$$

24

条件付独立性の判定方法

全変数の結合確率表を作って計算すれば分かるのだが、それはしたくない

- D-separation: ある証拠が与えられたとき、それに対応する変数を条件として、他の変数が条件付独立であるための十分条件を与える。
 - 証拠: ある確率変数達について、実現した値
- DAG上で、2変数間を、証拠変数がささぎるか否かを判定し、それで、条件付独立か否かを表している。

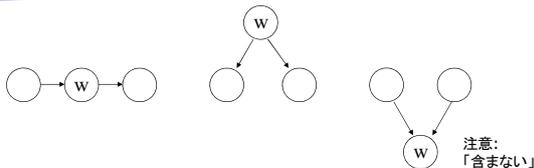
25

D-separation

- D-separation は、DAG上の変数間の独立性を調べるグラフ的なテストである
- A, B: 変数集合. 独立性を調べる
Z: 変数集合. 条件
Aの全ての変数とBの全ての変数間の全てのpathを調べる
- AとBはZを条件として(i.e. Zが観測されるとき)独立である ($A \perp\!\!\!\perp B \mid Z$) iff Aの全ての変数とBの全ての変数の間の全てのpathが通行止めである
- もしpathが一つでも通行可能であれば、独立も非独立もいえない
- D-separationが成立していないときに独立性を言おうと思えば、条件付確率表を調べるしかない
- ある pathが通行止めであるのは、このpath上のあるノード列が次のスライドに示す「通行止め」になっている場合である。

26

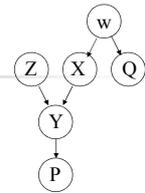
通行止め



	連続	分岐	合流
通行止め	$w \in Z$	$w \in Z$	$w \notin Z$ and 全子孫(w) $\notin Z$
通行可	$w \notin Z$	$w \notin Z$	$w \in Z$ or ある子孫(w) $\in Z$

27

例



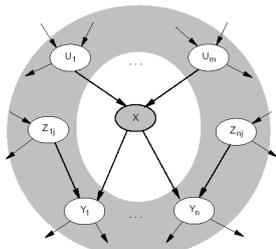
正しい関係 D separation による説明

- ($Q \perp\!\!\!\perp X, Y, Z, P \mid W$): $Q \leftarrow W \rightarrow X$ は分岐. Wを条件として通行止め
- ($Z \perp\!\!\!\perp X, W, Q \mid \emptyset$): $Z \rightarrow Y \leftarrow X$ は合流. Y及びその子孫Pを条件としないので通行止め.
- ($Z \perp\!\!\!\perp X, W, Q \mid P$): $Z \rightarrow Y \leftarrow X$ は合流. Yの子孫Pを条件としているので通行可能.
- ($Z, Y, P \perp\!\!\!\perp W, Q \mid X$): $W \rightarrow X \rightarrow Y$ は連続. Xを条件として通行止め.
- ($Z, Y, P \perp\!\!\!\perp W, Q \mid \emptyset$): $W \rightarrow X \rightarrow Y$ は連続. Xを条件としないので通行可能.

28

Markov Blanket

- Markov blanket: 親 + 子供 + 子供の親
- (中心にある)ノードは、Markov blanket 内の変数を条件として、ネットワーク内のどの変数からも、条件付独立である



29

推論

- ベイジアンネットワークで確率を計算することを推論という
- 一般に、推論では次の形のクエリーが扱われる:
 $P(X \mid E)$

E = 証拠 evidence 変数
X = 問い合わせる変数

30

推論

- クエリーは、例えば、：
 $P(\text{インフルエンザ} = \text{true} \mid \text{発熱} = \text{true}, \text{急性症状} = \text{true})$
- 注：悪寒と筋肉痛という変数がベイジアンネット中に現れているが、クエリー中では値が与えられていない (ie. 質問変数としても証拠変数としても現れていない)
- 未観測の確率変数として扱われる

31

BNにおける推論

他の例：Water-Sprinkler

- WetGrass が真のとき、2つの説明が可能：Rain か Sprinkler
 - どちらがよりありうるか？

$$\Pr(S=T \mid W=T) = \frac{\Pr(S=T, W=T)}{\Pr(W=T)} = \frac{\sum_{C,R} \Pr(C, R, S=T, W=T)}{\Pr(W=T)} = \frac{0.2781}{0.6471} = 0.430 \quad \text{Sprinkler}$$

$$\Pr(R=T \mid W=T) = \frac{\Pr(R=T, W=T)}{\Pr(W=T)} = \frac{\sum_{C,S} \Pr(C, S, R=T, W=T)}{\Pr(W=T)} = \frac{0.4581}{0.6471} = 0.708 \quad \text{Rain}$$

Rain が真であるのが理由である可能性がより高い

32

BNにおける推論 (2)

- Bottom-Up :**
 - 結果から原因へ → 診断 diagnostic
 - 例. エキスパートシステム, パターン認識, ...
 - 証拠・結果が与えられたとき、それを説明する最もありうべき仮説を求める
- Top-Down :**
 - 原因から結果へ → 推論 causal
 - 例. 生成モデル, 計画, ...
 - ある仮説のもとどのような結果がどのような確率で起こるか？
- Explain Away :**
 - Sprinkler と Rain は、WetGrass が真であることの説明に際し、競合している → この二つは、共通の子供 (WetGrass) が観測されると条件付依存となる

33

Explaining away effect

ある仮定(または仮定の集合)を支持する証拠が、その証拠とは相容れない(競合する)仮定の確からしさを減少させる効果、またはその現象

Call=true が観測されると、Earthquake=true の重要度(確からしさ)も Burglary=true の重要度も上昇する。しかし、Radio=true がさらに観測されると、Earthquake=true の重要度は上昇するが、Burglary=true の重要度は減少する。

to minimize the significance of by or as if by explanation <explains his faults, but does not try to explain them away— M. K. Spears>
<http://www.merriam-webster.com/dictionary/explain%20away>
 To dismiss or minimize the significance of (something) by means of an explanation or excuse: There is no way to explain away my carelessness.
<http://www.thefreedictionary.com/explain+away>

34

推論 – まとめると

- 因果推論
Causal Inferences $E \rightarrow Q \rightarrow Q$
- 診断推論
Diagnostic Inferences $Q \rightarrow Q \rightarrow E$
- 原因間推論
Intercausal Inferences $Q \rightarrow Q$
- 混合推論
Mixed Inferences $E \rightarrow Q \rightarrow E$

35

推論 – 結局のところ

- 条件付確率を求めること

$$P(Q \mid E) = \frac{P(Q, E)}{P(E)}$$

Q と E は確率変数(または当該確率変数のある値)の集合で、重なりはない
- そのためには、結合確率が高速に計算できるとよい

36

Naive な推論

BN で $P(Q|E=e)$ を解く naive なアルゴリズム

- 条件付確率を全て乗じ、全変数に関する結合確率分布を求める

$$P(Q|E) = \frac{P(Q, E)}{P(E)} = \frac{P(Q, E)}{\sum_q P(Q=q, E)}$$

- BN 構造が使用されず、変数が多いときこのアルゴリズムは実効的ではない
- 一般にこの推論は NP-hard

全然、BN ではない。

37

手計算でやってみよう

因果推論 Causal Inferences

原因から結果への推論

例: 窃盗が入ったとして、
 $P(J=true|B=true)$?

$$\begin{aligned} P(A=t|B=t) &= P(A=t, E=t|B=t) + P(A=t, E=f|B=t) \\ &= P(A=t|E=t, B=t)P(E=t|B=t) + P(A=t|E=f, B=t)P(E=f|B=t) \\ &= (0.95)(0.002) + (0.94)(0.998) \\ &= 0.94 \end{aligned}$$

$$\begin{aligned} P(J|B) &= P(J, A|B) + P(J, \neg A|B) \\ &= P(J|A, B)P(A|B) + P(J|\neg A, B)P(\neg A|B) \\ &= P(J|A)P(A|B) + P(J|\neg A)P(\neg A|B) \\ &= (0.9)(0.94) + (0.05)(0.06) \\ &= 0.85 \end{aligned}$$

略記: A とは $A=t$, $\neg A$ とは $A=f$

同様に $P(M|B)=0.67$ となる

38

手計算でやってみよう

診断推論 Diagnostic Inferences

結果から原因へ。

例: John が電話をした。
では $P(\text{burglary})$?

$$P(B|J) = \frac{P(J|B)P(B)}{P(J)}$$

$P(J)$ は? まず $P(A)$ が必要:

$$\begin{aligned} P(A) &= P(A, B, E) + P(A, \neg B, E) + P(A, B, \neg E) + P(A, \neg B, \neg E) \\ &= \\ &= 0.002517 \end{aligned}$$

$$P(B|J) = \frac{(0.85)(0.001)}{(0.052)} = 0.016$$

false positives 多し

$$P(J) = P(J, A) + P(J, \neg A)$$

$$=$$

$$=$$

$$= 0.052$$

手計算でやってみよう

原因間推論 Intercausal Inferences

Explaining away effect
が発生する。

Alarm が所与なら、 $P(B|A)=0.37$ 。
そこに Earthquake が真という証拠を加え
れば、 $P(B|A, E)=0.003$ 。

すなわち、 B と E は独立であるが、 A を条件
とした条件付独立ではないため、一方
に証拠があれば、他方の確率分布は変
化する可能性がある

$$\begin{aligned} P(B, A) &= \\ &= 0.00094002 \\ P(B|A) &= P(B, A)/P(A) = 0.3735 \\ P(B, E, A) &= P(B)P(E)(0.95) = 0.00000019 \\ P(E, A) &= \\ &= 0.00058132 \\ P(B|A, E) &= P(B, A, E)/P(A, E) = 0.003268 \end{aligned}$$

手計算でやってみよう

混合推論 Mixed Inferences

原因間推論と診断推論を
同時に

例: "John calls" かつ
"Earthquake=false":
 $P(A|J, \neg E)=0.03$

$$P(B|J, \neg E) = 0.017$$

$$P(A, J, \neg E) =$$

$$=$$

$$=$$

$$= 0.001742$$

$$P(\neg A, J, \neg E) =$$

$$=$$

$$=$$

$$= 0.04980$$

$$P(A|J, \neg E) = P(A, J, \neg E) / (P(A, J, \neg E) + P(\neg A, J, \neg E))$$

$$= 0.03379$$

41

一般化: 行すべき推論

- 一部の変数について、その値が観測される
- 仮に証拠変数と呼ぶ
- 推論 - 証拠変数以外の変数 X_i すべてについて、条件付確率 $P(X_i|E)$ を求める

- 一般には、計算量大 - (NP-hard)
- (ある条件のもと) 厳密値の計算方法がある
 - 確率伝播 belief propagation
- 従って、近似計算も用いられる

V_{e_1}, \dots, V_{e_n}

42

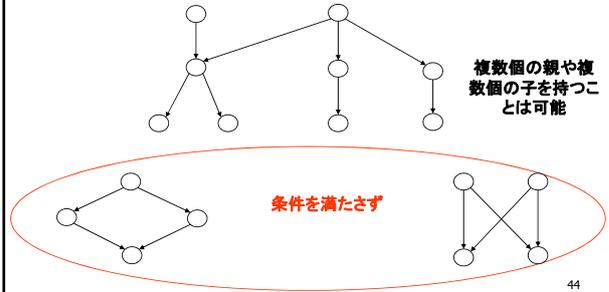
厳密な計算方法 – 信念伝播

- Judea Pearl, 1982 による
- 単結合グラフ singly-connected graph – どのノード間にもただか一つの無向路しか存在しない – についてのアルゴリズム.
- (下方に、上方に) (確率に基づく量を) 送る。これをメッセージと呼ぶ。(原理的には) 収束するまで繰り返す (単結合ならば必ず収束する)
 - π -message: ノード X の上方にある証拠 (事前分布) による量。下方に送られる
 - λ -message: ノード X の下方にある証拠 (事前分布) による量。上方に送られる

以下では少し異なる定式化を行う

43

単結合グラフ (または Polytrees)



44

変数の(積分)消去

例: 周辺分布 $p(x_5)$ の計算

$$\begin{aligned}
 p(x_5) &= \sum_{x_3} \sum_{x_4} \sum_{x_2} \sum_{x_1} p(x_1, x_2, x_3, x_4, x_5) \\
 &= \sum_{x_3} \sum_{x_4} \sum_{x_2} p(x_1) p(x_2 | x_1) p(x_3 | x_2) p(x_4 | x_3) p(x_5 | x_3) \\
 &= \sum_{x_3} p(x_5 | x_3) \underbrace{\sum_{x_4} p(x_4 | x_3)}_{m_{43}(x_3)} \underbrace{\sum_{x_2} p(x_3 | x_2) \sum_{x_1} p(x_1) p(x_2 | x_1)}_{m_{23}(x_3)} \\
 &\quad \underbrace{\hspace{10em}}_{m_{35}(x_3)}
 \end{aligned}$$

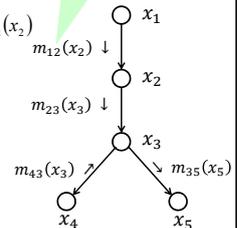
変数消去の順序は: 1, 2, 4, 3

45

メッセージ伝播

$m_{ij}(x_j)$: i から j へのメッセージと呼ぶ $m_{12}(x_2) = \sum_{x_1} p(x_2 | x_1) p(x_1)$
 i は総和をとって消去する変数, j はそれ以外

$$\begin{aligned}
 p(x_5) &= \sum_{x_3} p(x_5 | x_3) \sum_{x_4} p(x_4 | x_3) \sum_{x_2} p(x_3 | x_2) m_{12}(x_2) \\
 &= \sum_{x_3} p(x_5 | x_3) \sum_{x_4} p(x_4 | x_3) m_{23}(x_3) \\
 &= \sum_{x_3} p(x_5 | x_3) m_{23}(x_3) \sum_{x_4} p(x_4 | x_3) \\
 &= \sum_{x_3} p(x_5 | x_3) m_{23}(x_3) m_{43}(x_3) \\
 &= m_{35}(x_5)
 \end{aligned}$$



消去順序に依存することに注意

46

信念伝播 (Pearl, 1982)

$$m_{ij}(x_j) \leftarrow \sum_{x_i} \psi_{ij}(x_i, x_j) \prod_{x_k \in N(x_i) \setminus x_j} m_{ki}(x_i)$$

i : メッセージ発信元

j : メッセージ送信先

$N(i)$: i の近傍

$N(i) \setminus j$: j を除く、 i の近傍

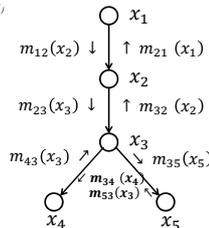
例

$$\sum_{x_3} p(x_5 | x_3) m_{23}(x_3) m_{43}(x_3) m_{35}(x_5)$$

周辺分布は:

$$p(x_i) \propto \prod_{x_k \in N(x_i)} m_{ki}(x_i)$$

但し、Pearl 1982 とは定式化が少し異なる



信念伝播 (Pearl, 1982)

$$m_{ij}(x_j) \leftarrow \sum_{x_i} \psi_{ij}(x_i, x_j) \prod_{x_k \in N(x_i) \setminus x_j} m_{ki}(x_i)$$

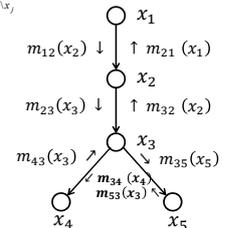
i : メッセージ発信元

j : メッセージ送信先

- (無向な木とした) 葉 i から開始 (葉 = エッジが一つのノード)

$$N(x_i) \setminus \{x_j\} = \emptyset$$

- 木構造から、各ノード i は、メッセージを j に送る前にすべての $N(x_i) \setminus \{x_j\}$ からメッセージを集めることができる



48

確率伝播(和積) 一般化

和積(sum-product)更新式

$$m_{ij}(x_j) \leftarrow \alpha \sum_{x_i} \psi_{ij}(x_i, x_j) m_{ii}(x_i) \prod_{x_k \in N(x_i) \setminus x_j} m_{ik}(x_k)$$

$$b_i(x_i) \leftarrow \alpha m_{ii}(x_i) \prod_{x_k \in N(x_i)} m_{ik}(x_k)$$

ただし、 α は正規化定数を表し $N(x_i) \setminus x_j$ は x_i の x_j を除く近傍を表す

$m_{ii}(x_i) = m_{ii}(x_i, y_i)$ は、非観測変数 x_i から観測変数 y_i へのメッセージを表す

49

確率伝播(最大-積)

最大-積(max-product)更新式

$$m_{ij}(x_j) \leftarrow \alpha \max_{x_i} \psi_{ij}(x_i, x_j) m_{ii}(x_i) \prod_{x_k \in N(x_i) \setminus x_j} m_{ik}(x_k)$$

$$b_i(x_i) \leftarrow \alpha m_{ii}(x_i) \prod_{x_k \in N(x_i)} m_{ik}(x_k)$$

ただし、 α は正規化定数を表し $N(x_i) \setminus x_j$ は x_i の x_j を除く近傍を表す

$m_{ii}(x_i) = m_{ii}(x_i, y_i)$ は、非観測変数 x_i から観測変数 y_i へのメッセージを表す

50

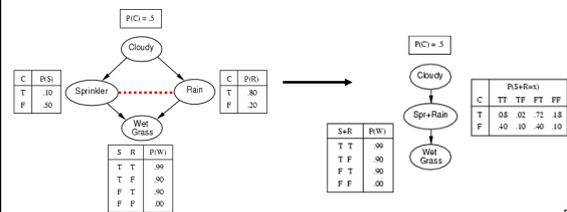
複雑度

- 単結合グラフ(polytree)上では、BP アルゴリズムは収束する。収束速度はグラフの直径に比例する – 高々線形
- 各ノードごとの作業は CPT のサイズに比例する
- 従って BP の計算量はベイジアンネットワーク中のパラメータ数に対し線形である
- 一般のベイジアンネットワークについては
 - 厳密な推論は NP-hard
 - 近似推論も(まともな近似は) NP-hard

51

より一般のグラフでは

- 信念伝播法が正しい値に収束するには、グラフが単結合でなければならない
- 一般的なグラフに対しては、それを **junction tree** に変換してから適用する方法が考えられている
- ただし、計算複雑度は、変換の結果発生するクランプ数に指数オーダーである → もし最適な junction tree を見出そうとすると、それは NP-hard



52

近似アルゴリズム

- なぜ?
 - ループを含むグラフに対して正確な計算を行おうとすると、指数関数時間がかかるため
 - また、連続分布を考えた場合、非ガウスであると、message は閉じた形式では表現できないため
- どうやって?
 - 決定的な近似: loopy BP, 平均場近似(変分ベイズ) 等
 - 統計的近似: MCMC (ギブスサンプラー), 等

- アルゴリズムにより、速度・精度のトレードオフがある(当然!)

53

ランダムサンプリング Random Sampling

- For $i = 1$ to n
 1. X_i の親ノード($X_{p(i, 1)}, \dots, X_{p(i, n)}$)を見つける
 2. 当該親ノードにランダムに(このアルゴリズムで)与えられた変数値を読み出す
 3. 次の値を表から読み出す
 $P(X_i | X_{p(i, 1)} = x_{p(i, 1)}, \dots, X_{p(i, n)} = x_{p(i, n)})$
 4. この確率に従い x_i の値をランダムに設定する

54

確率的シミュレーション Stochastic Simulation

- 知りたいのは $P(Q = q | E = e)$
- ランダムサンプリングを大量に行い次の個数を数える
 - N_e : $E = e$ となるサンプル数
 - N_q : $Q = q$ かつ $E = e$ となるサンプル数
 - N : ランダムサンプルの総数
- N が充分大きければ
 - N_q / N は $P(E = e)$ の良い推定値
 - N_q / N は $P(Q = q, E = e)$ の良い推定値
 - N_q / N_e は従って $P(Q = q | E = e)$ の良い推定値

55

補足: 連続変数値

- 条件付確率表を考える場合は、離散変数を仮定している
- 連続値変数に対しては、例えば、ガウス分布を仮定する。その場合、平均値と分散を用いることになる
- しかし、基本的には、離散変数を用いる。実際問題として、連続値であっても離散化することが多いからである。とはいえ、離散化のよしあしが結果に大きく影響するので、簡単ではない。

56

BNの学習(構築)

- 入出力:
 - 入力: 訓練データと事前知識
 - 出力: ベイジアンネットワーク
 - グラフとパラメータ
- 事前知識:
 - 最善(期待できない): ネットワーク構造
 - 変数間の依存関係
 - 事前分布

57

場合分け

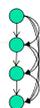
	構造は既知	構造が未知
完全データ	パラメータの統計的推測 (方程式)	構造を含めて離散最適化 (探索)
不完全データ	パラメータ最適化 (EM, 最急降下,...)	両方 (かなり大変,...)

58

構築

BN を構築する手続き:

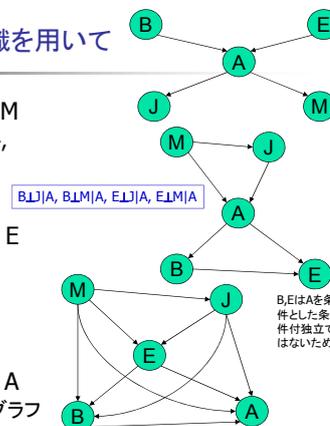
- 適用領域を記述する変数集合を選ぶ
- 変数の順序を定める
- 空のネットワークから開始し、変数をネットワークに、指定した順序に従い、一個ずつ付加していく
- $i=1$ から順に下記を行う
 - 第 i 番目の変数 X_i の付加:
 - すでにネットワーク中にある変数 (X_1, \dots, X_{i-1}) の中の変数から $pa(X_i)$ を $P(X_i | X_1, \dots, X_{i-1}) = P(X_i | pa(X_i))$ となるように定める
 - 領域知識を用いる
 - データから判断する
 - 有向弧を、 $pa(X_i)$ 中の各変数から X_i に結ぶ



59

例: 領域知識を用いて

- 順序: B, E, A, J, M
 - $pa(B) = pa(E) = \{\}$,
 - $pa(A) = \{B, E\}$,
 - $pa(J) = \{A\}$,
 - $pa(M) = \{A\}$
- 順序: M, J, A, B, E
 - $pa(M) = \{\}$,
 - $pa(J) = \{M\}$,
 - $pa(A) = \{M, J\}$,
 - $pa(B) = \{A\}$,
 - $pa(E) = \{A, B\}$
- 順序: M, J, E, B, A
 - 完全に結合したグラフ



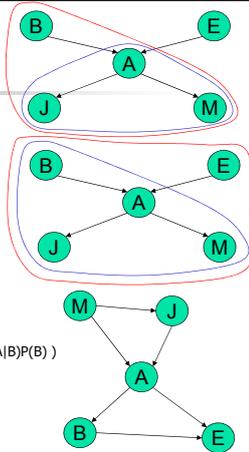
例: 説明

- 順序: M, J, A, B, E

$P(J|M)$. 簡略化できず
 $P(A|M, J)$. 簡略化できず

$$\begin{aligned} P(B|M, J, A) &= P(E, M, J, A, B) / P(M, J, A) \\ &= P(J|A)P(M|A)P(A|B)P(B) / (P(M|A)P(J|A)P(A)) \\ &= P(A, B) / P(A) \\ &= P(B|A) \end{aligned}$$

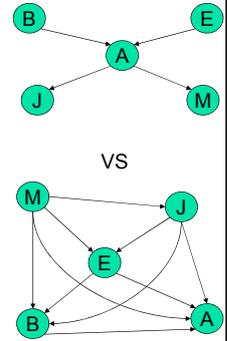
$$\begin{aligned} P(E|M, J, A, B) &= P(E, M, J, A, B) / P(M, J, A, B) \\ &= P(J|A)P(M|A)P(A|B)P(B)P(E) / (P(J|A)P(M|A)P(A|B)P(B)) \\ &= P(A, B, E) / P(A, B) \\ &= P(E|A, B) \end{aligned}$$



変数順序が大切!

どの変数順序を用いるか?

- 視点: 確率を計算する自然な順序. M, J, E, B, A はよくない. なぜなら $P(B | J, M, E)$ は自然でないから
- 視点: 弧の個数の最小化. M, J, E, B, A は宜しくない (弧が多すぎる), 初めの方がよい
- 視点: 因果関係反映, i.e. 原因が結果の前になる. M, J, E, B, A は宜しくない. というのも M と J は A の結果なのに A の前に来ている



領域知識がないとき

- データから判断する.
 - $P(X_i | X_1, \dots, X_{i-1}) = P(X_i | pa(X_i))$ となる最小の $pa(X_i)$ を見つける
 - しかし、データの偏りのため、厳密に上記等号が成立することは期待できない
 - そこで、ある程度のエラーを許容することになる。
 - しかし、どれだけ許容したらよいか分からない。
- 様々な情報量規準を用いる
 - データだけ (多項分布を仮定する (後述) ので、実は頻度) を見ても、データ数の不足・統計的偏りのため、条件付独立性は結論できない。
 - 誤差を見込むことになる。どの程度の誤差なら、「条件付独立」と見なすかという問に対して、それによって、簡単になるなら「条件付独立」と見なそうと答える。
 - その時の、残余誤差と簡単さとの trade-off を考え、判断するために、情報量規準を用いる。
 - MDL やベイジアンネットにおけるその精密化である BD (Bayesian Dirichlet) score がよく用いられる
- 説明は「補足」に

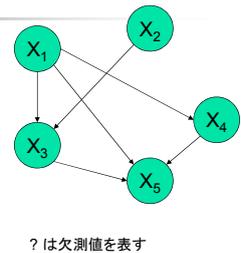
63

パラメータ学習

例:

- ある BN の構造が所与
- データ集合

X_1	X_2	X_3	X_4	X_5
0	0	1	1	0
1	0	0	1	0
0	?	0	0	?
...



? は欠測値を表す

- 条件付確率 $P(X_i | pa(X_i))$ の推定

64

パラメータの推定

- データには欠測値がないとする
- n 変数 X_1, \dots, X_n
- X_i の状態数 or 変数値の数: $r_i = |\Omega_{X_i}|$
- X_i の親変数の状態総数: $q_i = |\Omega_{pa(X_i)}|$
- 推定すべきパラメータ:

$$\theta_{ijk} = P(X_i = j | pa(X_i) = k),$$

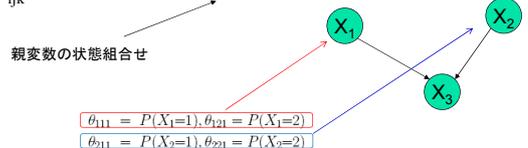
$$i = 1, \dots, n; j = 1, \dots, r_i; k = 1, \dots, q_i$$

65

簡単な例

例: BN を一つ. どの変数も2値 1, 2 をとるとする.

$$\theta_{ijk} = P(X_i = j | pa(X_i) = k)$$



$$\begin{aligned} \theta_{111} &= P(X_1=1), \theta_{121} = P(X_1=2) \\ \theta_{211} &= P(X_2=1), \theta_{221} = P(X_2=2) \\ pa(X_3) = 1: \theta_{311} &= P(X_3=1|X_1=1, X_2=1), \theta_{321} = P(X_3=2|X_1=1, X_2=1) \\ pa(X_3) = 2: \theta_{312} &= P(X_3=1|X_1=1, X_2=2), \theta_{322} = P(X_3=2|X_1=1, X_2=2) \\ pa(X_3) = 3: \theta_{313} &= P(X_3=1|X_1=2, X_2=1), \theta_{323} = P(X_3=2|X_1=2, X_2=1) \\ pa(X_3) = 4: \theta_{314} &= P(X_3=1|X_1=2, X_2=2), \theta_{324} = P(X_3=2|X_1=2, X_2=2) \end{aligned}$$

66

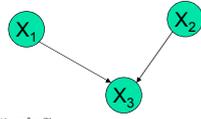
要は: 簡単な例

例: BN を一つ. どの変数も2値 1, 2 をとるとする.

$$\theta_{ijk} = P(X_i = j \mid \text{pa}(X_i) = k)$$

親変数の状態組合せ

P(X3 X1,X2)		X1, X2			
		1,1	1,2	2,1	2,2
X3	1	θ_{311}	θ_{312}	θ_{321}	θ_{322}
	2	θ_{321}	θ_{322}	θ_{323}	θ_{324}



最尤推定

サンプル数

P(X3 X1,X2)		X1, X2			
		1,1	1,2	2,1	2,2
X3	1	3	5	7	9
	2	7	15	23	31
		10	20	30	40

P(X3 X1,X2)		X1, X2			
		1,1	1,2	2,1	2,2
X3	1	3/10	5/20	7/30	9/40
	2	7/10	15/20	23/30	31/40

67

BN におけるパラメータ推定

- 次が求まる:

$$\theta_{ijk}^* = \frac{m_{ijk}}{\sum_j m_{ijk}}$$

- 言葉でいえば,
 $\theta_{ijk} = P(X_i = j \mid \text{pa}(X_i) = k)$ の最尤推定量は

$$\frac{X_i=j \text{ かつ } \text{pa}(X_i) = k \text{ となる事例数}}{\text{pa}(X_i) = k \text{ となる事例数}}$$

しかし、ご存じの通り、ちょっとした問題がある。

68

BN におけるパラメータ推定

- 実は次の形がよく使われている (Laplace correction):

$$\theta_{ijk}^* = \frac{m_{ijk} + 1}{\sum_j m_{ijk} + r_i}$$

- 言葉でいえば,
 $\theta_{ijk} = P(X_i = j \mid \text{pa}(X_i) = k)$ の最尤推定量は

$$\frac{X_i=j \text{ かつ } \text{pa}(X_i) = k \text{ となる事例数} + 1}{\text{pa}(X_i) = k \text{ となる事例数} + \text{「}X_i \text{ の変数値の個数」}}$$

なお、“+1” や “ r_i ” にはもっと一般的な形がある。
Dirichlet 分布を事前分布とすることに相当する。

69

補足

ベイジアンネットワークの学習

領域知識がない場合

70

BNの学習

BNをデータから構成する方法に2種類ある:

- 制約を発見していく方法
 - 統計的検定を行って、条件付独立な変数組を発見していく
 - これを満たす DAG を見つける
- スコア関数を用いる方法
 - DAG を比較するスコア関数を用いる。
eg. Bayesian, BIC, MDL, MML
 - データに最もよくfitする DAG を選ぶ

注: 通常、Markov等価性(説明してありません)による制約を考える。というのも、Markov等価なDAGは統計的には区別できないからである。

71

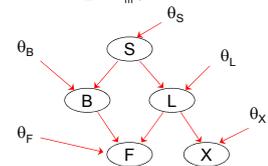
Bayes的方法(1)

(Cooper and Herskovits, 1992)

データを用いて、条件付独立性に関する統計的推定を行う
- 確率的関係をよりよく表現するモデルを探す

M - 構造を表す離散確率変数. 値 m はありうる DAG 構造.
Mの値は分布するとする. 確率分布を $P(m)$ で表す.

Θ_m - モデル m に対応した連続ベクトル値の確率変数(パラメータ). 値 θ_m はそのパラメータ値. Θ_m の値も分布する. 確率分布を $P(\theta_m \mid m)$ で表す.



G.F. Cooper and E. Herskovits (1992)
Machine Learning, 9, 309-47

Bayes的方法(2)

訓練データ集合を D , DAG構造 m の事後確率は, D が与えられたとして:

$$P(m | D) = \frac{P(m)P(D | m)}{\sum_{m'} P(m')P(D | m')}$$

但し

$$P(D | m) = \int P(D | \theta_m, m) P(\theta_m | m) d\theta_m$$

は周辺尤度である。例によって事前分布 $P(m)$ が一様分布であれば

$$P(m | D) \propto P(D | m)$$

従って、尤度最大化は事後確率最大化となる。

73

Bayes的方法 (3)

Cooper and Herskovits (1992) によれば、周辺尤度は次の通り

$$P(D | m) = \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(\alpha_{ij} + N_{ij})} \prod_{k=1}^{r_i} \frac{\Gamma(\alpha_{ijk} + N_{ijk})}{\Gamma(\alpha_{ijk})}$$

n - 全ノード数

q_i - ノード X_i の親ノード達の値全部の組合せ総数

r_i - ノード(離散確率変数) X_i の値の総数

α - 事前分布である Dirichlet 分布のパラメータ (i はノード, $1 \leq j \leq q_i$)

N - データ数. ノード i , 親ノード値の組合せ j , k 番目の値

この $P(D | m)$ は Bayesian scoring function として知られている。

G.F. Cooper and E. Herskovits (1992)
Machine Learning, 9, 309-47

74

計算例

次の DAG m_1 と訓練データ D を考える



$P(D | m_1)$ は

$$P(D | m_1) = \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(\alpha_{ij} + N_{ij})} \prod_{k=1}^{r_i} \frac{\Gamma(\alpha_{ijk} + N_{ijk})}{\Gamma(\alpha_{ijk})}$$

Y ($i=2$) に対し $q_i = 2$ (X は2値) かつ $r_i = 2$ (Y は2値). $j = 1$ に対応する項は

$$\frac{\Gamma(2)}{\Gamma(2+5)} \frac{\Gamma(1+4)}{\Gamma(1)} \frac{\Gamma(1+1)}{\Gamma(1)}$$

他の項も計算すれば $P(D | m_1) = 7.22 \times 10^{-6}$

R.E. Neapolitan, Learning Bayesian Networks (2004)

データID	X	Y
1	1	1
2	1	2
3	1	1
4	2	2
5	1	1
6	2	1
7	1	1
8	2	2

計算例 (続)

m_1 は、変数 X と Y の間に(条件付)独立性がないことを示す DAG (の Markov同値クラス) の代表と考えることができる。

m_2 をエッジがない DAG とすると $P(D | m_2) = 6.75 \times 10^{-6}$



さらに m_1 と m_2 の事前確率は等しい、すなわち $P(m_1) = P(m_2) = 0.5$ とすると m_1 の事後確率は m_2 の事後確率より大きくなる。

Bayesの定理により

$$\begin{aligned} P(m_1 | D) &= \frac{P(D | m_1)P(m_1)}{P(D | m_1)P(m_1) + P(D | m_2)P(m_2)} \\ &= \frac{7.215 \times 0.5}{7.215 \times 0.5 + 6.7465 \times 0.5} \\ &= \frac{7.215}{7.215 + 6.7465} = \frac{7.215}{13.9615} \approx 0.517 \end{aligned}$$

76

探索アルゴリズムの必要性

理想的には全 DAG の空間を網羅的に探索し、前述の Bayesian scoring function を最大化する DAG を見つけたい。

しかし、ノード数を大きく(ほんの少し小さく)しただけで、DAG の数は莫大なものとなる:

ノード数	DAG総数
1	1
2	3
3	25
4	543
5	29,281
10	4.2×10^{18}

様々な発見的方法が開発されている

77

K2 Algorithm (1)

(Cooper and Herskovits, 1992)

n 変数 $\{X_1, X_2, \dots, X_n\}$ 間に順序があると仮定する。すなわち, $j > i$ ならば, X_j は X_i の親にはなれないとする。

X_2 について

X_2 に親がないとして Bayesian score を求める

X_2 の親が X_1 として Bayesian score を求める。これがより大きければ X_1 から X_2 へのエッジをつける。

X_1 について

X_1 に親がないとして Bayesian score を求める

X_1 に親が一つだとして Bayesian score を求める。親がない場合より大きい score があればその最大値を与える X_1 からのエッジをつける。

次に第二番目の親を選んで同様のことを試みる。これを score が大きくなりないうまで続ける。



K2 Algorithm (2)

変数の順序を (X, Y, Z) とする

