

2.3.3 エビデンスの挿入 (エビデンスを証明とか訳すよりかエビデンスのまま)

あなたが何か新しい情報を得たときに、ベイジアンネットワークをつかって何か新しい確率を計算するでしょう。その新しい情報を得る以前の情報をタイプ $A=a$ とする。ここで A は変数を、そして a は A の状態を表す。 A は n 個の状態をもっており、それらの確率が $P(A)=(x_1, \dots, x_n)$ と表されるとしよう。そして、 A が状態 i かまたは j にあるときにのみ、情報 e が得られるものと仮定しよう。これをステートメントすると、状態 i と j を除いた他の状態は全て不可能なので、確率密度 $P(A, e) = (0, \dots, 0, x_i, 0, \dots, 0, x_j, 0, \dots, 0)$ というように表されるだろう。

ここで、 $P(e)$ は e の事前確率を表し、 $P(A, e)$ を A で周辺化することで得られる。また、 $P(A, e)$ は $P(A)$ を $(0, \dots, 0, 1, 0, \dots, 0, 1, 0, \dots, 0)$ で乗じた結果である。この $()$ 内の 1 の位置は i 番目と j 番目にあたる。

以下、スライドからの例。

Consider a variable A with five states $\alpha_1, \alpha_2, \alpha_3, \alpha_4, \alpha_5$ and with probability:

$$P(A) = \begin{pmatrix} \alpha_1 \\ \alpha_2 \\ \alpha_3 \\ \alpha_4 \\ \alpha_5 \end{pmatrix}, \quad \sum_{i=1}^5 \alpha_i = 1$$

Assume that we get the evidence e : " A is either in state α_2 or α_4 ". Then:

$$P(A, e) = \begin{pmatrix} 0 \\ \alpha_2 \\ 0 \\ \alpha_4 \\ 0 \end{pmatrix} = \begin{pmatrix} \alpha_1 \\ \alpha_2 \\ \alpha_3 \\ \alpha_4 \\ \alpha_5 \end{pmatrix} \cdot \begin{pmatrix} 0 \\ 1 \\ 0 \\ 1 \\ 0 \end{pmatrix}$$

Thus, e can be represented by a potential $\bar{e} = (0, 1, 0, 1, 0)^T$ and:

$$P(A, e) = P(A) \cdot \bar{e}$$

定義 2.4 A を n 個の状態をもつ変数とする。このとき A の finding とは、 0 と 1 からなる n 次元の表である。

ステートメント e 、すなわち「 A は状態 i か j のいずれかである」ということと、それに対応する $0/1$ の finding ベクトルとの間の違いを示すために、我々はときどきそ

の finding に対して太字の \mathbf{e} を用いることがある。意味的にいうと、finding とは、A のある状態が不可能であるというステートメントである。

ここで、ある結合確率テーブル $P(U)$ があり、 \mathbf{e} が finding であるとしよう。結合確率テーブル $P(U, \mathbf{e})$ は、 $P(U)$ のなかの A のエントリーのうち状態 i か j でない全てのエントリーを 0 でおきかえ、それ以外のエントリーはそのままにしておくことで得られるテーブルである。これは、 $P(U)$ を \mathbf{e} で乗じたことと同じことである。すなわち、

$$P(U, \mathbf{e}) = P(U) \cdot \mathbf{e}$$

となる。 $P(\mathbf{e}) = \sum_U P(U, \mathbf{e}) = \sum_U (P(U) \cdot \mathbf{e})$ であることに留意されたい。ベイジアンネットワークの連鎖法則を用いると、次の定理を得る。

Theorem: Let BN be a Bayesian network over the universe $\mathcal{U} = \{A_1, \dots, A_n\}$, and let $\bar{\mathbf{e}}_1, \bar{\mathbf{e}}_2, \dots, \bar{\mathbf{e}}_m$ be findings. Then:

$$\begin{aligned} P(\mathcal{U}, \mathbf{e}) &= P(\mathcal{U}) \cdot \prod_{i=1}^m \bar{\mathbf{e}}_i \\ &= \prod_{i=1}^n P(A_i | \text{Pa}(A_i)) \prod_{j=1}^m \bar{\mathbf{e}}_j. \end{aligned}$$

Hence, to find $P(A | \mathbf{e})$ we use:


$$P(A | \mathbf{e}) = \frac{\sum_{\mathcal{U} \setminus \{A\}} P(\mathcal{U}, \mathbf{e})}{P(\mathbf{e})}.$$

エビデンスのタイプによっては、finding として表すことはできないものもある。たとえば、あなたがだれかから、A の状態が a_1 にある確率が a_2 にある確率の 2 倍高いというステートメントを受け取ったとしよう。ベイジアンネットワークではこの手のエビデンスを扱うことが可能である。このとき、上述のステートメントは $(0.67, 0.33)$ の分布で表すことができ、定理 2.2 が適用できる。ただし、尤度のステートメントが真であるということが何を意味するか不明なので、 $P(\mathbf{e})$ をエビデンスの確率として解釈することはできない。したがって、 $P(U, \mathbf{e})$ のセマンティックスは不明である。我々は尤度のエビデンスについてこれ以上触れないこととする。

2.3.4 実際の確率計算

2.3.3 節で述べたように、また例 2.6 で説明したように、ベイジアンネットワークで確率を更新するということは、つまり連鎖法則をつかってユニバースの結合確率テーブル $P(U)$ を計算するということである。ただし、 U は、 $P(U)$ が手に負えないくらい大きくなる以前に大きくある必要はない。この節で我々は、結合確率テーブルが完全にわからなくても計算が実行できることを説明する。第 4 章で、確率の更新に対するアルゴリズムを詳細に扱う予定である。

図 2.17 に示すベイジアンネットを考える。全部で 10 個の状態をもつ。ここで、我々はエビデンス $e = \{D=d, F=f\}$ というエビデンスをもったうえで、 $P(A|e)$ を計算してみよう。



連鎖法則から次の式を得る。

$$\begin{aligned} P(U, e) &= P(A, B, C, d, f, G, H) \\ &= P(A)P(H)P(B|A, H)P(C|A)P(d|B, H)P(f|B, C)P(G|C) \end{aligned}$$

ここで、 $P(d|B, H)$ とは、 D のエントリーを状態 d に修正して得られる B と H にわたるテーブルを指す。つまり、条件付き確率テーブルは、 $D=d$ に初期化されたといいかえてもよい。ここで、我々は 10 の 7 乗ものエントリーをもつ $P(U)$ の完全なテーブルを計算する必要はないことに注目する。もしエビデンスが入力されるまで待つとしたら、このケースでは 10 の 5 乗のエントリーしかないテーブルで作業する必要があるだろう。あとで、我々は多くても 1000 個のエントリーしかないテーブルで作業すればよいことがわかる。

$P(A, e)$ を計算するのに、我々は $P(A, B, C, d, f, G, H)$ から変数 B, C, G, H を周辺化する。周辺化する順番は結果に影響を与えないので、 G から始めよう。

$$\begin{aligned}\Sigma_G P(A, B, C, d, f, G, H) \\ = \Sigma_G P(A)P(H)P(B|A, H)P(C|A)P(d|B, H)P(f|B, C)P(G|C)\end{aligned}$$

右辺において、最後のテーブルだけが G をその領域にもっているので、分布法則 (1.4 節参照) から次のようになる。

$$\begin{aligned}\Sigma_G P(A, B, C, d, f, G, H) \\ = P(A)P(H)P(B|A, H)P(C|A)P(d|B, H)P(f|B, C) \Sigma_G P(G|C)\end{aligned}$$

我々は $\Sigma_G P(G|C)$ を計算する必要はない。実際、 C の各状態 c に対して、我々は $\Sigma_G P(G|c) = 1$ である。したがって、計算は必要なく、次の式をえる。

$$\begin{aligned}\Sigma_G P(A, B, C, d, f, G, H) \\ = P(A)P(H)P(B|A, H)P(C|A)P(d|B, H)P(f|B, C)\end{aligned}$$

次に、 H について周辺化する。同様にして次の式を得る。

$$\begin{aligned}\Sigma_H P(A, B, C, d, f, H) \\ = P(A)P(C|A)P(f|B, C) \Sigma_H P(H)P(B|A, H)P(d|B, H)\end{aligned}$$

上の式の右辺で $P(H)$ と $P(B|A, H)$ と $P(d|B, H)$ を乗じて、それを H について周辺化する。その結果を $T(d, B, A)$ とすると、次の式をえる。

$$P(A, B, C, d, f) = P(A)P(C|A)P(f|B, C) T(d, B, A)$$

最後に、この積を計算して、それから B と C について周辺化する。なお、5 つの変数をもつ $P(A, B, C, d, f, G, H)$ のなかで、三つより多い変数のテーブル (上の $P(H)$ と $P(B|A, H)$ と $P(d|B, H)$ の積は A, B, H の三つの変数のテーブルだから扱える) を扱えないことに留意する。我々がここで用いた手法は、変数削減と呼ばれ、次のように説明できる。

テーブルの集合 T があるとする。これを変数 X について周辺化しよう。我々は T からその領域に X をもつ全てのテーブルを抽出し、それらの積を計算する。そして、その積を X について周辺化し、その結果のテーブルを T に加える。

＊ ＊ スライドの方にもっとわかりやすい変数削減の例がのっている。