

グラフィカルモデルの活用による裁判実務における 確率的推論の実践可能性

弁護士 木本 茂樹

信和法律事務所

要旨

裁判における事実認定では、心証の正確な度合いを求める必要はないから、確率的推論を用いるにあたっては、厳密な推論を行う必要はない。条件付独立性に基づくベイジアンネットワークの特質を活かすことにより、推論の過程を単純化した上で、新証拠の追加や経験則などの強弱の評価の変化が結論に与える影響を検証し、また、適切な結論を導くことが可能であり、グラフィカルモデル(マルコフ・モデル)を用いることで確率的推論を裁判実務においても実践的に活用することが期待できる。

キーワード: 事実認定, 確率的推論, ベイジアンネットワーク, グラフィカルモデル

1. はじめに

1.1 確率的推論と実用上の問題点

事実認定における確率的推論の活用は、Finkelstein and Fairley (1970)に始まり、その後、わが国においても、太田(1982)により事実認定への確率論の導入が提唱された。確率的推論は、論理的に一貫している¹上、主観的な信念の度合いを確率によって表現するというアプローチは、裁判所に顕出された証拠のもとでの要証事実に対する合理的な信念の度合いが問題となる事実認定とも親和的である。にもかかわらず、現在に至るまでわが国の裁判実務においては、確率的推論の根幹をなすベイズの定理やこれに基づく確率的推論は、少なくとも明示的な形では、おそらく全く使われていない²。

その理由の一つとしては、確率的推論を行うにあたっては、正確な心証度を計算

する必要があるがそのための実践的な方法がないと考えられている³ことがあるように思われる。確かに、条件付確率の積を計算することによって事後確率が理論的には計算できることとしても、多数の証拠や事実からなる複雑な事案においてこれを実践するのは極めて複雑かつ困難であり、裁判実務でこれを実践するのは現実的ではない。

一方、欧米では、裁判実務へのグラフィカルモデル、特に、ベイジアンネットワークの活用による確率的推論の実践を試みた先行研究がいくつかある。例えば、Taroni et al. (2006)は、法科学においてベイジアンネットワークの活用を、また、Kadane and Schum (2003)は、現実の事案をベイジアンネットワークを用いて分析を行っているほか、Fenton et al. (2012)は、法律家が「確率論や簡単な数学」⁴を理解できないでも利用可能なベイジアンネットワークツールを提唱している。グラフィカルモデルを活用する方法は、確率変数間の条件付独立性などを利用して、推論の構造を単純化しながら視覚化するという点で優れているが、構築されたモデルに基づいて厳密な推論を行う場合には、やはり計算過程が複雑になるため、人間が計算するのは現実的ではない。そのため、これらの研究においては、ソフトウェアが数値計算を行うことが前提となっている⁵。

確かに、計算をコンピュータに委ねれば、計算の煩雑さからは解放される。しかし、ソフトウェアを使う場合でも、グラフの構築は人が行わなければならない、現実の関連する事実が多数あるような複雑な事案においては、ベイジアンネットワークの構築も決して容易ではない。加えて、推論の過程の計算をソフトウェアに委ねてしまうと、その過程がブラックボックス化してしまうおそれがある。さらに、裁判では、新しい証拠が加わったら、結論がどのように変わり得るかや、経験則についての評価を変えたら結論がどのように変わるかについても検討する必要がある。計

本発表は、2015年本学会全国大会で行った発表(木本(2015))の前半部分を敷衍し、発展させたものである。

¹ Jaynes(2003), Cox(1961).

² 草野(2014).

³ 例えば、太田(1982)104頁。

⁴ Fenton et al. (2012) p.2.

⁵ Taroni et al. (2006)ではHUGIN、Kadane and Schum (1996)ではERGO、Fenton et al. (2012)とFenton and Neil (2013)ではAgenaRiskというソフトウェアをそれぞれ用いている。

算をソフトウェアに委ねると、そのような仮定を行うたびにコンピュータを走らせて計算をしてみることになるが、その数が膨大になる可能性がある。

このため、正確なモデルの構築をするという方針をとる限り、ソフトウェアに計算を委ねても、煩雑な作業から解放されるわけではない。実際、欧米でも確率的推論が法律家の支持を広く受けているとは言い難いように思われる。

1.2 本稿の目的

事実認定において判断を求められているのは、心証度が一定の度合い(証明度)を超えるか否かであり、その具体的な数値を正確に求める必要は必ずしもない。このため、実際の裁判においては、すべての証拠が推論のすべての過程やその結論に決定的な影響を与えているわけではなく、むしろ、一部の証拠のみが決定的な役割を果たしており、他の証拠や経験則の多少の変動は結論を左右しないということがしばしばある。そのため、裁判実務で確率的推論を行うとしても、様々な事実を当然に考慮に入れて何らかの作業をするのではなく、推論を極力単純化することを念頭に置きながら、必要に応じ、これらの事実がどのように結論に影響を与えるかや、証拠の変動や経験則に変動が結論にどのような影響を与えるかを検証できるような方法が望ましい。本稿では、このような観点から、グラフィカルモデルを活用した実践的な確率的推論の方法を検討する。

2. 確率的推論とマルコフ・モデル

2.1 確率的推論の基本構造

確率的推論は、オッズ形式で表現すると、 e を事実認定において前提としうる事実(証拠的事実)、 u_x を要証事実、 p^* を証明度として、

$$\frac{p(u_x|e)}{p(u_y|e)} = \frac{p(u_x, e)}{p(u_y, e)} > \frac{p^*}{1-p^*} \quad (1)$$

という不等式の成否の問題と捉えられる。そして、(1)式の分子は、積の法則から、

$$p(u_x, e) = \prod p(u_x|e_1, e_2, \dots, e_n) \cdots p(e_2|e_1)p(e_1) \quad (2)$$

のように条件付確率の積の形で表す(因数分解する)ことができるが、証拠的事実が複数ある場合には、他の証拠的事実のもとでの条件付確率や証拠的事実と要証事

実とのつながりがすぐわかるわけではなく、計算に必要な条件付確率($p(e_{i+1}|e_1, e_2, \dots, e_i)$ や $p(u|e_1, e_2, \dots, e_n)$ など)が経験則や物理法則から得られるとは限らず、(1)式から直ちに結論を導けるわけではない。

そこで、(a)経験則や物理法則により、条件付確率のおおよその値がわかるように適当な事実(中間事実)を確率変数として追加し、(b)確率変数間の条件付独立性を利用して、(1)式を実際の計算が可能ないように変形することになる。

ここで確率変数 Y を与えたもとで確率変数 X と確率変数 Z が条件付独立であるとは、

$$p(X|Y, Z) = p(X|Y) \quad (3)$$

が成立することと定義され⁶、確率変数 Y についての情報が与えられている場合には、 Z についての情報は X の判断に影響を与えないことを意味する。条件付独立性を用いると、複数の確率変数の同時確率分布がより少数の確率変数を要素とする条件付確率なる積の形で因数分解することができる。例えば、確率変数 Z を与えたもとで確率変数 X と確率変数 Y が条件付独立である場合、

$$p(X, Y, Z) = p(X)p(Y|X)p(Z|Y) \quad (4)$$

と因数分解することができる。このように、確率変数 $W=(W_1, W_2, \dots, W_n)$ について、同時確率 $p(W)$ が確率変数間の条件付独立性から、 W の部分集合 pa_i ($i=1, 2, \dots, n$)を用いて、

$$p(W) = \prod_i p(w_i | pa_i) \quad (5)$$

の形に因数分解されるとき、 pa_i を w_i の親、 w_i を pa_i の子という。

次に、中間事実を追加するというのは、例えば、 A のもとで B が生じる確率はわからないが、 A のもとで M が生じる確率と M のもとで B が生じる確率はわかるときに、確率変数として M を追加し、 $p(B|A)$ を、全確率の公式から、 $\sum_M p(B|M)p(M|A)$ に置き換えて計算をするというものである。

これらを用いて、中間事実を $m=(m_1, m_2, \dots, m_n)$ とすると、(1)式の左辺は、

⁶ (4)式は、 $p(X, Z|Y) = p(X|Y)p(Z|Y)$ 、 $p(X|Y, Z) = p(X|Z)$ とそれぞれ同値である。詳しくは、Pearl(2000) 黒木訳(2009) pp.10-12, Pearl(1988) pp.82-90参照。

$$p(u_x, e) = \sum_m p(u_x, m, e) \quad (6)$$

と変形し、さらに、 e, m, u_x を適当な順序に並べ直したものを $\{w_i\}$ 、 e, m, u_y を適当な順序に並べ直したものを $\{v_j\}$ とすると、条件付独立性と積の法則を利用して、

$$p(u_x, e) = \sum_m \prod_i p(w_i | pa_i) \quad (7)$$

と積の形に因数分解することができる。確率的推論の最も直接的な方法は、(7)式と u_y についての(7)式に対応する式について、各中間変数についてその積を求め、足しあわせるというものであるが、この方法では、(a)中間事実の数やそのとりうる値が増えると、定めるべき条件付確率の値が指数的に増大する上、(b)単純にすべての積を求めて足し合わせるという計算では、計算量も指数的に増加することになるし、(c)事前確率や条件付確率が正確ではない場合には、それらの値がとりうる誤差を考え、その値を変えた場合の結論に与える影響を考察する必要があるが、これもまた膨大な計算量になり、実用的でない。そこで、推論を単純化する方法を検討する必要がある。

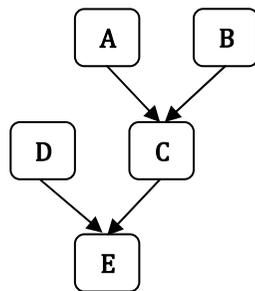


図1 ベイジアンネットワークの例

2.2 ベイジアンネットワーク

グラフィカルモデルは、ノードと呼ばれる点/節と辺と呼ばれる線によって、確率変数間の関係を視覚的に示したものである。ベイジアンネットワークは、各位確

率変数間の構造を有向グラフを用いて視覚化したもので、因数分解された同時確率分布において親から子に有向辺を引くことによって得られる⁷。例えば、図1は、同時確率分布 $p(A, B, C, D, E) = p(A) p(B) p(C | A, B) p(D) p(E | C, D)$ に対応するベイジアンネットワークである。ベイジアンネットワークの特長は、グラフから確率変数間の条件付独立性の成否が判断できることである。

グラフの基本的な構成要素として3つのノードがある場合を考えると、その場合として、図2のように3つの場合が考えられる。

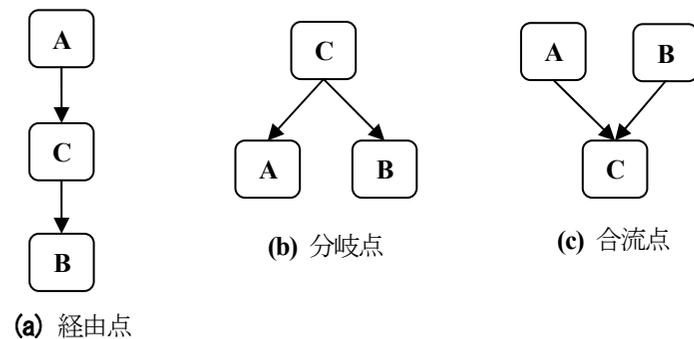


図2 3つの確率変数の関係

図2(a)のCのように一方(A)が親から、他方(B)が子への有向辺となっているものは経路点、図2(b)のCのように、いずれも子(A, B)への有向辺がでているものは分岐点、図2(c)のCのようにいずれも親(A, B)からのエッジが来ているものを合流点と呼ばれる。図2(a)と図2(b)では、CのもとでAとBは条件付独立となるが、図2(c)では、逆に、AとBは独立だが、Cを与えると従属する。ノードの数が増え、グラフが複雑になっても、有向分離(d-separation)と呼ばれる基準により、ノード間の条件独立性の判断ができる。

2.3 マルコフ・モデル

⁷ ベイジアンネットワークについての厳密な定義や詳しい説明については、Pearl(1988)p.116以下参照。

図2(a)と図2(b)がいずれも、 C のもとで A と B が条件付独立となる同時確率分布を示していることから明らかなように、ある同時確率分布を表すベイジアンネットワークは複数あり得る。しかし、同じ事案でそれぞれの当事者や分析者が異なる構造のグラフを用いると、議論が錯綜しかねない。そこで、グラフを作成するにあたっては、有向辺が因果関係という意味を有するようになった方が便利である。親を持たない確率変数が互いに独立であるという前提でベイジアンネットワークにおける有向辺に「因果関係」、すなわち、矢印の元のノードと矢印の先にあるノードが原因と結果という関係⁸で結ばれるように構築されたのがマルコフ・モデルである⁹。

マルコフ・モデルにおけるグラフの構築方法は、次の3つのステップからなる；

- (a) ノードとなる確率変数を定める、
- (b) ノード間を直接の因果関係の有無に基づいて有向辺で結ぶ¹⁰、
- (c) 条件付確率表を作成する。

マルコフ・モデルの特長は、確率変数間の因果関係の存否のみでグラフの構造が決まり、因果関係の大小を表す構造方程式の関数の形式や条件付確率表の値には依存しないことにある。つまり、(b)までのステップでは、ある確率変数を示すノードと他の確率変数を示すノードとの間に直接の因果関係があるか否かの情報さえあれば足りる¹¹。これは、「因果関係の有無についての知識がそれに対応する数値的確率についての知識に先立って得られる」¹²ことがしばしばあることを考えると、事実認定の問題においてもモデルを構築する上での重要なメリットである¹³。

⁸ 有向辺は、確率変数間の関係を示すものであるから、厳密な意味での因果関係でなくともよい。本稿でも、Fenton and Neil (2013)と同様に、定義・合成を示すものとしても用いる。

⁹ 詳しい議論については、Pearl (2000)黒木訳(2009)p.30以下参照。

¹⁰ 「直接の因果関係」があるかは、他の確率変数との間で相対的に決まるから、例えば、 C を加えると、 A から C へ直接の因果関係があり、 C から B へ直接の因果関係があるが、 A から B へは直接の因果関係はない(C を介した因果関係しかない)ために、 A から B への有向辺が削除されるということはあり得る。

¹¹ Pearl (2000)黒木訳(2009)pp.25-26。

¹² Pearl (2000)黒木訳(2009)p.26。

¹³ Pearl (2000)黒木訳(2009)p.25以下、Fenton and Neil (2013)p.172以下。

2.3.1 従来のチャート・ダイアグラムとの相違

事実認定においてチャートやダイアグラムなどの視覚的方法を用いるのは決して新しい発想ではなく、古くはウィグモアのチャート¹⁴やFriedmanのダイアグラム¹⁵などがある。これらとマルコフ・モデルによるベイジアンネットワークグラフとは主に以下の3点で異なる。

まず、ベイジアンネットワークでは、ノードが事実の存否やその内容を示す確率変数を表しているため、ある事実が存在する場合と存在しない場合などが一つのノードに包摂されている。このため、関連する事実が増えても、ノードの数が指数的には増えず、グラフを比較的単純なままに留めておくことができたり、ノード間の関係を有向辺の有無や向きによって判断できるという長所がある一方で、ある事実があった場合となかった場合が同じグラフで表現されることが短所となりうる。

第二に、ウィグモアのチャートでは様々なシンボルが用いられているのに対して、マルコフ・モデルのベイジアンネットワークにおいては、ノード間を結ぶ線は、因果関係ないし定義や合成を意味する1種類の有向辺だけで結ばれており¹⁶、複雑な記号を習得する必要がないことが長所となる一方、ある事実が他の事実に与える影響の内容や大きさをグラフから読み取ることができない。

第三に、ベイジアンネットワークでは、グラフの構造は、ノード間の作用の大きさに依存しない一方で、あるノードが他のノードにどのような影響を与えるかを定量的に決められる。つまり、必要に応じて、定量的な分析を行うことができる。これらの特徴が、以下に見るように、事実認定において、ベイジアンネットワークを用いることで、推論の過程を極力単純化しながら、必要な限度で推論の精緻化する選択肢を残すことを可能にしている。

3. 単連結グラフにおける推論の単純化

¹⁴ Wigmore (1913), Wigmore (1937)。

¹⁵ Friedman (1986)。

¹⁶ ウィグモアのチャートについては、Kadane and Schum (1996)p.67以降を参照。

3.1 はじめに

推論過程をどのようにすれば単純化できるかを考えるためには、厳密な推論がどのようになされるかを理解する必要がある。そして、推論を単純化する上で核となるのが、単連結グラフ(ループ¹⁷のないグラフ)における確率伝搬法(Belief Propagation)である。本節では、まず、Pearl(1988)の確率伝搬法について簡単に説明した後、単連結グラフにおける推論の単純化について述べる¹⁸。

3.2 確率伝搬法

3.2.1 用語・記法

ある経路上に、ノードがA, B, Cの順に並んでいるとき、Aから見てBを(Cよりも)内側のノード、Cを(Bよりも)外側のノードと呼ぶ。また、証拠的事実 \mathbf{e} のもとでの要証事実 u の条件付確率 $p(u|\mathbf{e})$ を(\mathbf{e} のもとでの) u の蓋然性(probability), u のもとでの \mathbf{e} の条件付確率 $p(\mathbf{e}|u)$ を(\mathbf{e} のもとでの) u の尤度(likelihood)¹⁹と呼び、それぞれ π と λ で表す。また、Pearl(1988)にならって、確率変数全部の条件付確率をベクトルないし行列で表す。例えば、 $U = \{u_X, u_Y\}$ のとき、 $p(U) = (p(u_X), p(u_Y))^T$ (T は転置)、 $p(\mathbf{e}|U) = (p(\mathbf{e}|u_X), p(\mathbf{e}|u_Y))$ である。また、同じ行数をもつ行列AとBについて、AとBのそれぞれの要素を順に掛け合わせたものをABと表記する²⁰。

¹⁷ あるノードからエッジを辿り、どのエッジも二度以上通ることなく元のノードに戻る場合、その経路をループ(loop, 閉路)と呼ぶ。

¹⁸ 本節での確率伝搬法の説明は、Pearl(1988)での説明の要旨を纏めたものである。より詳細な説明については、Peal(1988)を参照。

¹⁹ 尤度と蓋然性との間には、ベイズの定理から、 \bar{u} を u の否定として、

$$p(u|\mathbf{e}) = \frac{p(u)p(\mathbf{e}|u)}{p(u)p(\mathbf{e}|u) + p(\bar{u})p(\mathbf{e}|\bar{u})}$$

が成り立つ。この式からも明らかなように、尤度 $p(\mathbf{e}|u)$ が大きいということは、蓋然性 $p(u|\mathbf{e})$ が大きいことの必要条件でも十分条件でもない。

²⁰ 例えば、 $\pi = (\pi_X, \pi_Y)^T$, $\lambda = (\lambda_X, \lambda_Y)^T$ のとき、 $\pi\lambda = (\pi_X\lambda_X, \pi_Y\lambda_Y)^T$ である。



(a) $p(u|\mathbf{e})$: 蓋然性 (b) $p(\mathbf{e}|u)$: 尤度

図3 蓋然性と尤度

3.2.2 確率伝搬法

確率伝搬法の基本的な考え方は、ノード間の条件付独立性を活用し、外側のノードから内側のノードに順に蓋然性(π)または尤度(λ)を送る操作を繰り返して(周辺)確率を求めるというものである。今、要証事実の確率変数を $U = \{u_X, u_Y\}$, U の親または U からみて親よりも外側にある証拠を \mathbf{e}^+ , U の子または子よりも外側にある証拠を \mathbf{e}^- とする。

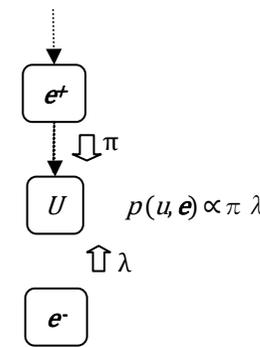


図4 確率伝搬法の基本構造

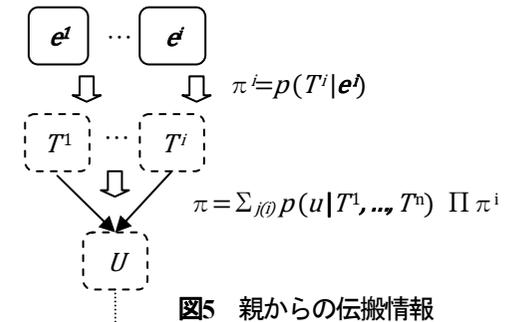


図5 親からの伝搬情報

そうすると、

$$p(U, \mathbf{e}) = p(\mathbf{e}^+)p(U|\mathbf{e}^+)p(\mathbf{e}^-|U) \tag{8}$$

となるが、オッズを考える際には、 U の値に左右されない分母と分子で共通の係数

は約分により消えるから、 $p(e^+)$ は議論の上では無視できる。すなわち、

$$p(U, e) \propto p(U|e^+)p(e^-|U) = \pi\lambda \tag{9}$$

となり、要証事実の親の側については、親か親よりも外側にある証拠のもとでの要証事実の蓋然性を求め、要証事実の子の側については、子か子よりも外側にある証拠のもとでの要証事実の尤度を求め、これらの積を求めることにより、要証事実の心証度を得られることを示している（図4）。

さらに、親からの情報については、 U に $T=(T^1, \dots, T^n)$ の n 個の親があり、 T^i の外側にある証拠を e^i 、親が取り得る値 $(t_{j(1)}^1, \dots, t_{j(n)}^n)$ のもとでの要証事実の蓋然性を $p(u | t_{j(1)}^1, \dots, t_{j(n)}^n)$ とすると、

$$p(u | e^+) \propto \sum_{j(i)} p(u | t_{j(1)}^1, \dots, t_{j(n)}^n) \prod_i p(t_j^i | e^i) \tag{10}$$

となる（図5）。この式は、親からの情報が、親の外側にある証拠のもとでの親の条件付確率 $\pi^i = p(t_j^i | e^i)$ と親が取り得る値のもとでの要証事実の蓋然性により得られる、つまり、親の外側にある証拠から親に向けて、蓋然性 π^i が伝搬され、これらと確率条件表から得られる条件付確率 $p(u | t_{j(1)}^1, \dots, t_{j(n)}^n)$ を組み合わせることで、順次蓋然性 π が要証事実 U に向けて伝搬されることを意味している。

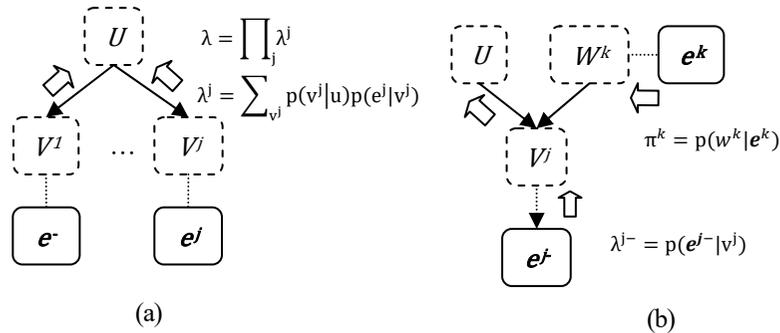


図6 子からの確率伝搬

同様に、子からの情報の伝搬についても、子を V^k 、 V^k の外側にある証拠を e^k とすると、

$$p(e^-|U) = \prod_k p(e^k|U) \tag{11}$$

であるから、それぞれの子の外側にある証拠のもとでの尤度を考え、その積となる。つまり、それぞれの子の外側にある証拠のもとでの尤度が、それぞれの子から伝搬されると考えられる。そして、さらに、子の外側にある証拠のもとでの尤度は、子 V^k の U 以外の親を W 、 U の親である証拠、または W の外側にある証拠を e^W 、子の子かその外側にある証拠を e^{k-} とすると、

$$p(e^k|u) \propto \sum_v p(e^{k-}|v^k) \sum_w p(w|e^W)p(v^k|u, w) \tag{12}$$

となる。つまり、証拠 e^W のもとでの当該親の蓋然性 $\pi = p(w|e^W)$ 、子 V^k の子かその外側にある証拠のもとでの v^k の尤度 $\lambda^k = p(e^{k-}|v^k)$ 、 u と W のもとでの V^k の尤度 $p(v^k|u, w)$ によって求められる。

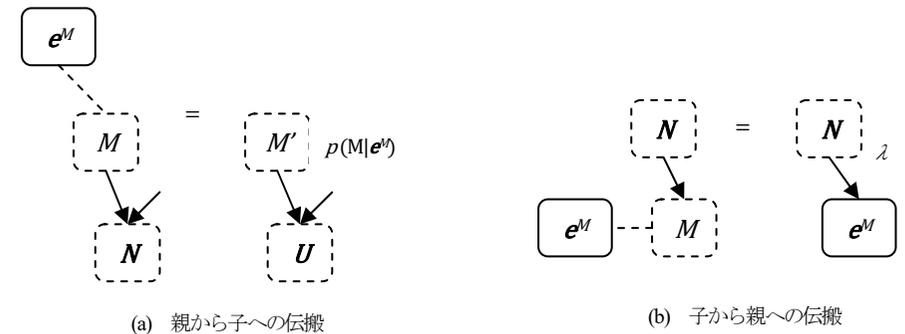


図7 確率伝搬法の意味

T や W 、 V より先のノードについても同様に、その外側にある証拠のもとでの蓋然性や尤度が伝えられ、それを組み合わせて内側のノードに向けて、蓋然性ないし尤度を伝搬していると理解できる。つまり、確率伝搬法では、グラフの一番外側から要証事実に向けて、親から子については外側の証拠のもとでの蓋然性を、子から親へは同様に尤度をそれぞれ情報として順に伝搬していると理解できる。このため、親から子へ情報が伝えられるときは、親と親の先にあるノードを、親の外側のノード

ドにある証拠的事実のもとでの親の蓋然性を確率分布にもつノードに、また、子から親へ情報が伝えられるときは、子の子の外側にある証拠にそれぞれ置き換えることができる（図7）。

3.3 推論の単純化

確率的推論において厳密な推論を行うためには、条件付確率表をすべて埋めなければならない、それは確率伝搬法を用いる場合も同様である。しかし、例えば、 n 個の変数をもつ親が m 個ある場合において、子がある値をとる確率を求める場合、条件付確率表を作成するには、 m^n 個の場合を考える必要があり、全く現実的ではない。現実の事案において確率的推論を活用するには、推論を単純化する方法を考える必要がある。単連結グラフにおいて推論を単純化する主な方法としては、(1)ノードの統合による条件付確率表の単純化と(2)分節的条件付けの2つがある。

3.3.1 ノードの統合

前述の通り、あるノードに証拠的事実ではない親が増えると、条件付確率表の値は指数的に増大する。そこで、親ノードを適当に統合して条件付確率表の単純化も推論を単純化する上で有力な方法の一つである²¹。例えば、Cが生じる原因として、大きくAとBの2の原因があり、Aに影響を与える要素として、D, E, Fという事実が、Bに影響を与える要素としてG, Hという事実があったとする。今、各事実が2値からなるとしても、A, B, D~Hを親、Cを子とする条件付確率表は、 $2^8 (=256)$ 通りの場合を考える必要がある。他方、D~FのCに与える影響がBによらず、G, HのCに与える影響がAによらないことを利用して、A, D, E, FとCとの間にJ, B, G, HとCとの間にKというそれぞれ2値をとるノードを挿入できるとすると、A, D, E, Fを親、Jを子とする条件付確率表は、 $2^4 (=16)$ 通り、B, G, Hを親、Kを子とする条件付確率表は、 $2^3 (=8)$ 通り、J, Kを親、Cを子とする条件付確率表は、 $2^4 (=4)$ 通りの場合を考えればよく、全体の作業量も大きく減ることになる。

3.3.2 分節的条件付け

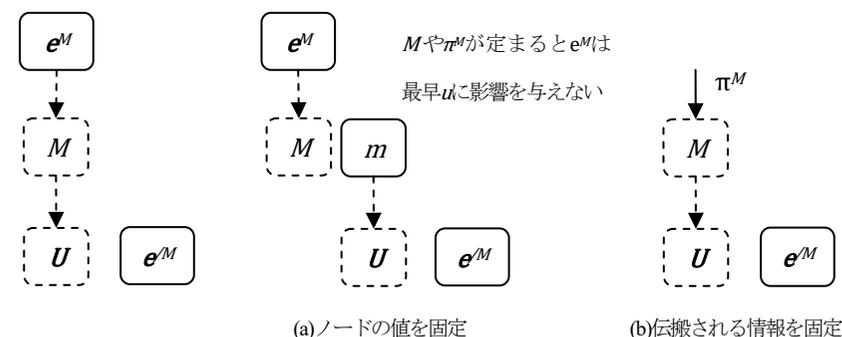


図8 分節的条件付け

第二は、グラフが2つの条件付独立な部分グラフに分かれるようにあるノードの確率変数の値を特定の値に固定する分節的な条件付けである。単連結グラフにおいては、分岐点や経由点のノードは、そのノードによって二分される二つの部分グラフをブロックするから、そのノードの確率変数の値を固定すると、一方の部分グラフは他方の部分グラフに影響を与えない。同様に、確率伝搬法で伝達される情報（蓋然性や尤度）を固定すれば、その外側にあるノードは、内側の確率変数の値に影響を与えなくなる（図8）。このため、例えば、あるノードMについて、取り得る一方の当事者にとって最も有利な値をとっても当該当事者に有利な結論が導かれず、あるいは逆に、最も不利な値をとっても当該当事者に不利な結論が導かれずであれば、その値をとったものとして推論を行うと、当該ノードの先の推論を行う必要がなくなる（図8(a)）から、枝刈り²²により、Mの先にあるノードを捨象することができる²³。

²² 推論に無関係なノードをグラフから除去すること。詳しくは、Darwiche (2009) p.143 以下参照。

²³ 推論の単純化として、ある事実については、それが生じた可能性が極めて低いため、その可能性を捨象するという方法もある。例えば、WがA=aという供述をしているときに、その信用性を疑う事情がない場合に、A=aを証拠的事実であると扱うような場合である。しかし、これについては、信用性を疑う事情がない（WがA=aという供述をしていることから、甲が強く推認できる）というだけでは、A=aが真であるとして推論を進めてよいわけではないので注意が必要である。

²¹ 詳しくは、Darwiche (2009) p.114以下参照。

例えば、犯行現場近くで被告人に似た人を目撃したという目撃者Wの証言があったとしても、被告人が犯人ではないことを示すより決定的な証拠（例えば、防犯カメラの映像 e ）があれば、Wが正しいか（本当に、証人Wは、被告人Aに似た人を見たのか）を判断するまでもなく、被告人は犯人ではないと判断でき、目撃証言の信用性を基礎づける事実（例えば、明るさや証人の視力、犯人との関係その他虚偽供述の動機）など目撃という事実の外側にある事実についての推論を省略できる（図9(a)）。

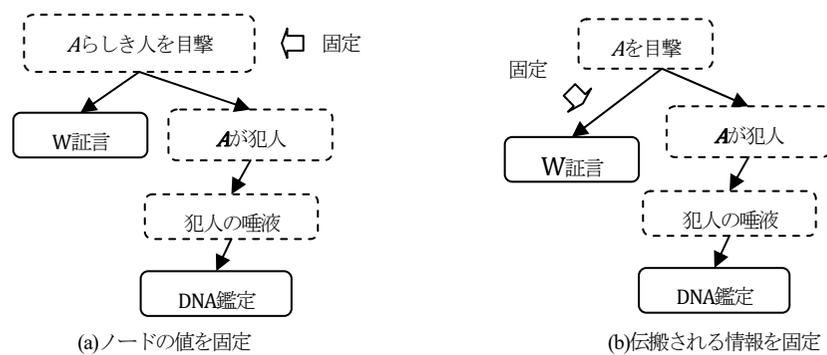


図9 分節的条件付けの例

同様に、 e^M のもとでの M の蓋然性である π^m を特定の値に固定して適切な結論が得られる場合（図9(b)）にも、 e^M はもはや結論には影響を及ぼさないから、やはり、枝刈りにより、 M の先にあるノードを除去することができる。具体的には、確率伝搬法により、外側のノードから送られてくる情報は、外側の証拠のもとでの蓋然性や尤度であるから、その値について、「一定の値以下である」などの評価をした上で、一方当事者に最大限有利に評価をしても結論が変わらないとして、正確な値やその影響を求めることを省略するというものである。

例えば、証人Wが被告人を現場近くで目撃したと証言している場合において、仮に、証人Wの証言の信用性を損ねるような事実がなかったとしても、被告人を目撃していない可能性が一定程度あり、（DNA鑑定などの）他の証拠からすれば被告人が犯人ではない可能性が高いという推論（図9(b)）などはその一例である。他の例

としては、例えば、ある証拠 e についても要証事実の蓋然性を高めることはわかっているが、既に他の証拠から要証事実の心証度が証明度を超えている場合に、 e がいずれにも有利に働かない証拠として推論を進める（ e の具体的な影響を求めない）場合などがある。

3.4 小括

単連結グラフにおいては、確率伝搬法により、外側の証拠のもとでの蓋然性や尤度を情報として内側のノードに伝えることを繰り返すことにより、求めるべきノードの確率が得られる。また、あるノードを条件付けすれば、その外側での推論や内側に影響を与えなくなる。これらの性質を利用して、外側のノードのもとでの蓋然性や尤度を適当に評価したり、あるいは、他の強い証拠の影響などから結論に影響を与えないことを利用して、適当な条件付けを行うことで推論を単純化し、複雑な計算を避けることが期待できる。

4. 複連結グラフにおける推論の単純化

4.1 複連結グラフの問題点

前節の議論は、グラフが単連結という前提でのものであるが、実際の裁判では、グラフが単連結となることはほとんど期待できない。例えば、同一人物が複数の客観的な事実について供述している場合には、その客観的な事実の間の関連と、供述の信用性を判断する根拠となる事実を通じたつながりが生じるために、これらの事実の間でループが生じるからである。グラフが複連結の場合には、ループの存在により、「外側」のノードすべてから情報を受けることができず、循環が生じてしまうため、確率伝搬法についての前節までの議論をそのまま用いることはできない。ループがある場合の計算方法としては、変数を併合してグラフが単連結になるようにする方法（ジョイントツリーグラフ）や収束するまでループの中で確率伝搬法を繰り返す方法（loopy belief propagation）などがあるが、いずれも、推論の単純化が容易ではなく、裁判実務における実用性という観点からすると適当ではない。

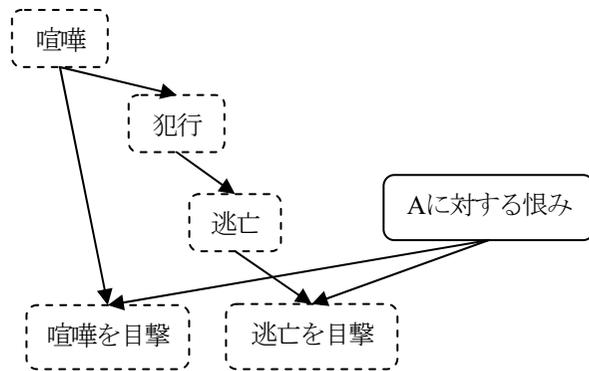


図10 供述証拠によりループが生じる例

4.2 開環的条件付け

ループのある場合の対処方法としては、ループ上の適当な確率変数について条件付け(開環的条件付け: cutset conditioning²⁴)を行うことによって、ループを解消してグラフを単連結にする方法があり、推論の過程に生じた計算に意味を持たせるという観点からするとこれが最も望ましいと思われる。

例えば、図11では、ループを構成するノードの一つである確率変数 $A=\{a_1, a_2\}$ の値が定まったとすると、BからAを経てCに影響を与えることはなくなるから、グラフは実質的に単連結になる。このようにしてグラフを単連結にした上で同時確率を求めるという作業をAの取り得る値すべてについて行い、その期待値を求める²⁵ことで、必要な値を得ることができる。

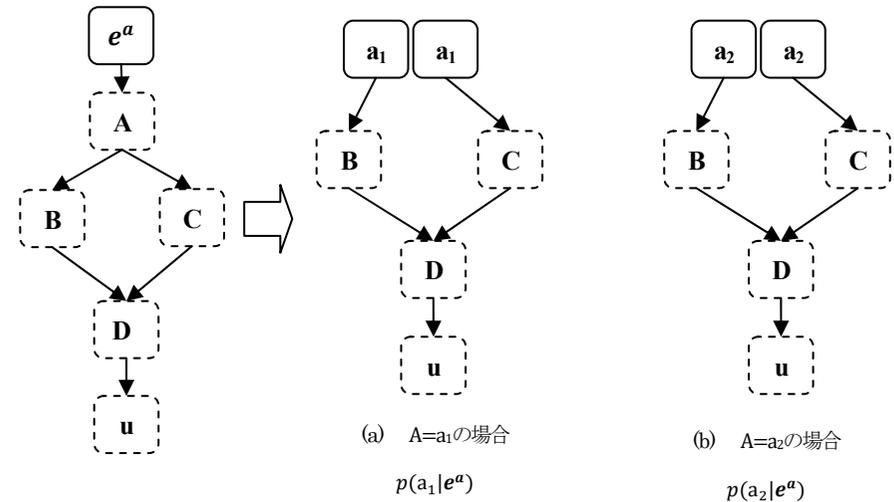


図11 開環的条件付け

4.3 推論の単純化

4.3.1 開環的条件付けと推論の単純化

開環的条件付けでは、ループが増えると開環するために条件付けが必要なノードの個数が増えていく。したがって、単連結にするためにそれらのノードを同時に条件付けを行わなければならないとなると、条件付けによって考えなければいけない場合の数は指数的に増大する²⁶。しかし、推論を単純化するという観点からすれば、結論が適切な限度で条件付けの値を決めればよいから、例えば、開環した一方の側のノードの値や条件付確率の値と他方の側の値を変えた上で、条件付けしたり、一方の値のみを条件付けするということもあり得る。

4.3.2 分節的条件付けと推論の単純化

また、分節的条件付けを併用することにより、開環的条件付けによってグラフを単連結にしなくても、推論を単純化することができる場合がある。分節的条件付けの基本的な考え方は、ある確率変数の集合 A のもとで、要証事実 u と確率変数の集合

²⁴ Pearl (1988)p.204以下, Darwiche (2009) p.178以下参照. なお, cutset conditioningという語は, Darwiche (2009)による.

²⁵ 式で表すと, A のもとで e^A と u 及び e^A 以外の証拠 e^A がそれぞれ条件付独立になるとき, 全確率の公式より,

$$p(u|e^A, e^A) = \sum_A p(a|e^A) p(u|a, e^A)$$

となる. つまり, a と e^A のもとでの u の条件付確率を求め, これを e^A のもとで a が生じる蓋然性で重み付けすればよい. 詳しくは, Darwiche (2009) p.178以下参照.

²⁶ 例えば, 単連結にするために m 個の値をとる確率変数 n 個について条件付けを行うとすると, n^m 通りの場合を考える必要がある.

B が条件付独立であれば、

$$p(U|A, B) = p(A|B)p(U|A) \quad (13)$$

で与えられるから、 A を条件付けによって固定した推論ができるならば、 B については調べる必要がないというものである。この議論は、 B の内部においてループがあるかには左右されないから、複連結のグラフにおいても、適当なノードの集合 A を条件付けしても、 U についての正しい結論が得られるならば、 B について詳細に考察する必要はなくなる。

また、ループ同士を有向分離するノードがある場合にも、ループごとに場合分けをすることができ、この場合、場合分けの数は積ではなく、和になる²⁷。

4.4 まとめ

複連結グラフの場合においても、開環的条件付けによって、グラフを単連結にすることで、推論を単純化することができる。このときに、同時に条件付けを行うノードの数が増えれば、計算量は指数的に増大することになるから、理論的には、条件付けは推論過程が必ず単純化できることを保証するものではないが、複連結の場合でも、条件付独立性を利用した分節的条件付けなどの活用によって、推論の過程を一定程度単純化することは可能である。

5. 要証事実が複数の場合

これまでは要証事実の確率変数が一つである場合について議論してきたが、現実の事案では、証明対象となる事実の確率変数が複数になる場合がある。例えば、原告がある時点での被告の承諾の意思表示と別の時点での承諾の意思表示を主張している場合、それぞれについて当該意思表示の有無を1つの確率変数とすると、原告の主張が認められるためには少なくともいずれかの時点での承諾の意思表示が認められればよいことになる。また、そもそも要件事実が連言的に定められている場合には、個々の主要事実ではなく、要件事実の連言、すなわち、要件事実全部が全体と

²⁷ 例えば、 n_1 個の値をとるノードと n_2 個について場合分けを行う場合、 $n_1 n_2$ 個ではなく、 $n_1 + n_2$ 個の場合分けで済む。

して証明の対象となっていると考える方が規定の趣旨と整合的であるとも考えられる。

このような場合には、複数の確率変数について、連言的にまたは選言的に特定の値が含まれる条件付確率を求めることになる。しかし、複数の確率変数の値が問題となる場合でも、単一の確率変数の値が問題となる場合と本質的な違いはない。

理論的には、新しいノードを作り、問題となる確率変数のノードすべてから新しいノードに有向辺を結び、問題となっている複数のノードが与えられたときに問題となっている確率変数の値が、証明が認められるために必要な条件（例えば、上の承諾の例でいえば、いずれか一つの事実が認められる場合）を満たすかによってその出力を変える、つまり、証明の成否を判定するように定めれば、この新しいグラフもまたベイジアンネットワークになり、新しく加えられたノードのみの値によって証明の成否を判断することになるから、従前の議論を用いることができる²⁸。

また、事案によっては、グラフの構造などを利用して単純化することも考えられる。例えば、複数の確率変数の値が選言的に含まれる場合、その中の一つの値の確率が証明度を超えることを示すことができれば、証明としては十分である。

6. グラフィカルモデルによる確率的推論の実践的方法

前節までに見たように、グラフィカルモデルを用いて確率的な推論を行うことのメリットは、推論構造の単純化と精緻化が必要に応じて自在にできるという点にある。現実の事案において確率的推論を行うにあたっては、この性質を最大限利用することになる。すなわち、モデルを構築するにあたって、関連する証拠的事実をすべて最初から考慮に入れるのではなく、重要と思われる証拠的事実と要証事実のみを取り上げ、これに必要に応じて中間的事実を追加してモデルを構築する。その上

²⁸ 貸借契約の解除における信頼関係破壊の法理（最判昭28.9.25・民集第7巻9号979頁）や更新拒絶における正当事由など複数の評価障害事実や評価根拠事実からこれらの要件の該当性が問題となる場合も、生の事実の確率変数としては、複数の具体的な評価根拠事実の存否が問題となるが、これらの生の事実から「信頼関係破壊の有無」などの主要事実への有向辺を引くことで、同様に扱うことができる。

で、証拠的事実を追加する場合には、それがどこに追加され、どのようにして結論に影響を与えるかを考慮しながら、必要があれば、その影響の態様や大きさをより詳細に分析し、そうでなければ、そもそもノードとして追加するのを省略したり、あるいは、ノードとして追加してもその大きさ(条件付確率表)の作成を省略したり、簡素化したりすることができる。また、別の証拠的事実を追加することによって、これまで詳細な検討をしなくて済んでいた部分を考慮する必要が生じたときには、その部分について、条件付確率表をより正確にするなどして、推論を精緻化すればよい。

そして、グラフィカルモデルは、このような特質のため、裁判所による結審後の事実認定の場面だけではなく、当事者による訴訟の準備は訴訟の進行、争点の整理、判決後の検証などでも用いることができる。訴訟の準備の場面では、手持ちの証拠的事実をもとに、証明をするためにはどの事実を補強や弾劾する証拠的事実が必要かや、どのような証拠が相手方から提出されることが予想され、それが結論にどのような影響を与えるか、また、それに備えてどのような証拠を準備しておけばよいかなどを視覚的に把握できる。また、訴訟進行の場面では、相手方から提出された証拠が結論に与える影響を把握し、それに対して、反証や反論が必要か、必要だとしてどのような対応が必要かを考えることができる。また、検証の場面では、結論に至った過程のうち、誤りのある部分が是正されていればどのような結論が導かれたか、そして、その誤りを是正することによって結論を変更することができるか、あるいは、推論に誤りがないとして、どのような証拠的事実を追加すれば結論を覆すことができるかなどを考察することができる²⁹。

²⁹ 訴訟プロセスのグラフィカルモデルの活用による理解は、囲碁に似たところがある。囲碁においては、盤面の一部分に打つ箇所がなくなるまで集中的に打つわけではなく、大場や急場と呼ばれる重要箇所に先着していく。そして、特に序盤では、自分が打つ手の大きさを正確には計算せず、せいぜい目算するに過ぎない。そして、対局が進むにつれ、必要に応じて形勢判断を精緻化していく。また、相手の手について、その部分や勝敗に影響を与えないと判断すれば、手を抜いて別の部分を打つこともある。同様に、訴訟でも、当事者は、重要だと思われる証拠を提出していき、一部分の事実を反論されても、重要性がないと判断すれば、それに応じないこともある。また、証拠を提出するにあたっては、それが自分の主張する要

なお、グラフィカルモデルと前節までに述べた推論の単純化の方法によってあらゆる事案について常に、推論を単純化して、正しい結論を導くことができるとは限らない。結論が微妙な問題については、緻密な計算をしなければ正しい結論が得られず、単純化ができないことはあり得るし、前提となる条件付確率の値が正確でなければ、誤った結論が導かれるということもあり得る。しかし、すべての運動について必要な精度で正しい予測ができるとは限らないからニュートン力学の正しさや有用性が否定されるわけではないように、単純化できない問題が残るから確率的推論の正しさやグラフィカルモデルの有用性が否定されるわけではない。

7. グラフィカルモデルを用いた確率的推論と従来の理論の比較・検証

グラフィカルモデルを利用することによって、従来の理論がどのような前提に基づいてなされていたかやどのような不備があったかなどをより明確に認識することができるとともに、例えば、証拠が互いに独立であるなど、必ずしも現実的ではない仮定でしか成り立たなかった理論について、どのような場合にそのような理論が妥当な近似として活用できるのかを認識し、活用できる。

本節では、①従来の事実認定において用いられてきた論証型アプローチとシナリオ型アプローチ、②事実認定における統計学の役割、③ラプラスの式、④因果関係における原因事実の特定と間接反証を例にこの点について簡単に説明する。

7.1 従来の事実認定の方法

確率的推論によらない従来の事実認定のアプローチとしては、大きく分けて①前提命題に経験則や科学法則などを適用して別の命題を導き、それと他の命題と経験則や科学法則などをさらに適用して順次命題を導いて結論を得る論証型のアプローチと、②事実経過についてのストーリー(事件の筋)を立てて、それと証拠との総

証事実の確率を何%あげることになるかというような正確な計算は行わない。囲碁において、対局者が、「石の形」などの視覚的な側面から形勢判断をし、応手を考えていくように、グラフィカルモデルは、当事者や裁判所が、グラフの構造という視覚的な情報から形勢判断をし、訴訟進行のあり方を決めていく一助になりうる。

合的な整合性から判断する物語型のアプローチの2つがある。以下では、これらのアプローチが確率的推論によってどのように理解できるかについて簡単に述べる。

7.1.1 論証型アプローチ

論証型アプローチは、証拠や「動かし難い事実」から出発し、これに経験則や科学法則などの一般命題を適用することで、別の事実を推認し、その事実にもた経験則や科学法則などの一般命題を適用して別の事実を導くことを繰り返すことにより結論を得る方法である³⁰。

ベイジアンネットワークは、原因となるノードから結果となるノードを前者から後者に向けた矢印で結んでいるから、グラフ上の矢印が推論の方向を図示しているわけではないが、関係のあるノード同士のみが矢印で結ばれているから、グラフを用いた確率的推論でも、推論は必然的にグラフのリンクに沿って行われることになる。したがって、各論証は、確率グラフィカルモデルにおいては、親から子、もしくは、子から親への局所的な確率の伝搬によって示されていると理解できる。実際、確率伝搬法は、最も外側のノードから内側のノードに情報を伝搬することを繰り返していき、これは証拠や「動かし難い事実」から順に要証事実に向けて推論を行っていく方法と類似している。

他方、論証アプローチは、論証の前提となる経験則や科学法則が例外を含んでいたり、事実が蓋然的であったりするために、得られる結論も不確実なものになってしまうが、その不確実性の程度を判断することができない(Verheij et al.(2016))ことにその限界がある。「動かしがたい事実」から推論を行う場合でも、証拠Eからある事実Aの蓋然性が高いことが導かれるとしても、その事実Aが真であるとして議論を続けることには論理的な飛躍があり、誤った結論を導きかねない。これに対して、確率的推論は、「ブール代数を蓋然性を含む場合に拡張」³¹したものであるから、必要に応じて定量的で一貫した議論が可能である。

7.1.2 シナリオ型アプローチ

シナリオ型アプローチは、想定しうる特定の事実経過(シナリオ)のうち、どちらのシナリオが経験則に照らして自然で証拠と整合しているかによって判断する方法である。

シナリオは、確率的推論においては、確率変数の特定の値の組み合わせとして理解できる³²。シナリオという概念を用いると、グラフにおいて、すべてのノードから特定の値を抽出したものを組み合わせたものは、1つのシナリオであると理解できるから、(7)式は、想定可能なシナリオの同時確率を足し合わせたものであり、確率的推論とは、当事者双方が、それぞれ自己の主張(請求等)を基礎づけるために採用できるシナリオを考え、それらの同時確率の比が(証明度によって定まる)一定の割合を超えているかの判断であると理解することができる。Vlek et al. (2016)が、シナリオとサブシナリオという概念を導入しているように、シナリオは考察の対象となる事実の一部のみを含むものでも構わないが、いずれにしても論証型アプローチが、確率的グラフィカルモデルでは、局所的な確率の伝搬として表されるのに対し、シナリオ型アプローチは、複数のノードを含むより大域的な推論構造として理解できる。

このため、確率的推論からすると、検討すべきシナリオが無数にあることになる³³。これに対して、現実の裁判で検討されるシナリオは、それぞれの当事者でせいぜい1つか2つに過ぎないことが多いが、これは以下のように説明できる。

まず、複数の詳細な事実経過のうち、一部の事実をまとめたものを1つのシナリオと扱っていることが挙げられる。例えば、犯行時刻に犯行現場から離れた甲という場所にいたというアリバイを主張している被告人にとっては、犯行が誰によってなされたかは特定できないし、する意味もない。したがって、被告人が犯人ではないとすると、例えば、 $B \sim E$ が犯人である可能性があるとしても、(Aが犯行時に甲にいた \cap Bが犯人である)というように、犯人を特定したシナリオを想定するので

³² Verheij et al. (2016).

³³ 中間事実がM個、中間事実 m_i の値の数を d_i とすると、 $\prod_{i=1}^M d_i$ 個のシナリオがあることになるが、これが確率伝搬法など推論の単純化を必要とした理由でもある。

³⁰ Verheij et al. (2016).

³¹ Bishop (2009) p. .

はなく、A以外の者が犯人であるという事実をまとめた(Aが犯行当時に甲にいた)という事実を一つのシナリオと捉えるのが自然である。

第二に、理論的には複数の筋があり得るとしても、1つのシナリオの蓋然性が他と比べて十分大きい場合、他のシナリオを考慮する必要がなくなることがある。特に、裁判において問題となる事実、当事者の少なくとも一方が体験した事実であることが少なくない。このため、理論的には事実を確定できなくても、当事者としては当然知っていなければならず、必然的に当事者が主張するシナリオが限定されることになる。この結果、当事者が主張している事実と異なるシナリオについては、その事実が真実だとすると当該当事者の主張が間違っていることになり、他の事実の信用性を傷つけることになるから、結果として当該シナリオが真である蓋然性を下げることになる。

シナリオ型アプローチに関連して確率的推論の判断枠組から導かれる重要な結論として、シナリオは単独では、その適否を判断することができないということが挙げられる。双方の当事者のシナリオの同時確率の相対的な大小によって証明の成否を判断するというのが確率的推論の基本構造であり、あるシナリオの同時確率の値のみで証明の成否を判断することはできない。つまり、あるシナリオが経験則に反しないというだけでなく、他のシナリオでは合理的に説明することができない事実や極めて説明が困難な事実がなければ、証明がなされたとは言えない。「被告人が犯人でないとしたならば合理的に説明できない(あるいは、少なくとも説明が極めて困難である)事実関係が存在」することを求める最判平22.4.27(2010)も、この観点から理解することができる。

7.2 確率的推論と統計学

統計学は、近年ベイズの手法(ベイズ統計学)が広く取り入れられてきている分野であるが、事実認定における(ベイズの定理を用いた)確率的推論は、統計学そのものではない。統計学は、多数のデータからそのデータに共通する性質や法則を抽出する学問であるのに対し、事実認定は、専ら1回限りの事実(歴史的な事実)を考察の対象とするものであるからである。「統計的結果は、その明確さの点で非

常に魅力があるから、ある特殊な場合に、われわれの知識の範囲内にあるような、より重要ではあるがより漠然とした考慮事項を忘れさせる。」というケインズ³⁴の言葉は、事実認定における統計学の位置づけを端的に示している。

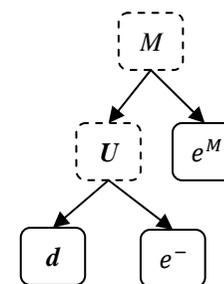


図12 統計学の位置づけ

統計学が用いられるのは、条件付確率表などのように、当該事案の事実の一部の組み合わせの場合だけであり、当該事案における事実全部を含めた統計値が得られるということはずまない。したがって、統計学は、特定の親子間の条件付確率表を作成したり、あるいは、特定のノード間の因果関係の有無を決めたりするのには有用となりうるが、そこで得られた値を絶対的なものとして扱い、(正確な数値を得られない)他の証拠を無視するのは適切ではない。例えば、図12で、Mをランダムに抽出したもとの、dというデータが得られた場合の統計値から、 $p(U|M)p(d|U)$ が統計学的に正しく得られていても、 e^M や e^- という証拠がある場合に、これらの影響($p(M|e^M)$ や $p(e^-|U)$)が経験的にしかわかっておらず、統計学的には正確な数値として求められないとしても、その影響を無視することはできない。

同様に、科学的な専門家などに専門的な知見を求める場合でも、当該専門家が、当該事案におけるすべての事実を考慮に入れて結論を導くことができるわけではない³⁵。したがって、専門家に意見を求める場合には、どのような事実を前提として

³⁴ Keynes (2009) 佐藤隆三訳 (2010) (2010) p.373.

³⁵ 例えば、供述の信用性の判断など、当該専門家の専門的な知見に含まれない事実については、これを考慮に入れないで(あるいは、何らかの前提を付して)鑑定がなされることに

結論を導いたのかを明確にした上で、当該専門家が考慮していない事実を裁判所が考慮に入れた上で適切な結論が導けるような形で鑑定人に意見を聴取する必要がある、その範囲を明確にするにあたって、グラフィカルモデルを活用することが考えられる。

7.3 ラプラスの式

ラプラスの式は、「経験則の確率」を e_i と($i=1,2, \dots, n$)すると、その推定事実 u_x が真である確率 $p(u_x | e)$ は、

$$p(u_x | e) = \frac{\prod e_i}{\prod e_i + \prod (1 - e_i)} \quad (14)$$

という式で与えられるとするものである³⁶。(15)式からも明らかなように、 $e_i > 0.5$ であれば、 $p(u_x | e)$ の値を高めることになるが、倉田(1969)では「経験則の確率」が定義されておらず、どのようにしてその値が定めるのかが不明であり、理論の射程や利用方法が不鮮明になっている。

このラプラスの式は、グラフィカルモデルを用いると、ナীবベイズの特別な場合として説明できる。ナীবベイズモデルとは、図13のように、要証事実を与えると証拠的事実がすべて互いに条件付独立となるモデルである。このとき、要証事実 u_x のもとでの証拠 e^i の条件付確率 $p(e^i | u_x)$ を λ_x^i 、 u_y のもとでのそれを λ_y^i とすると、オッズは、

$$\begin{aligned} \frac{p(u_x, e)}{p(u_y, e)} &= \frac{\prod_i p(e^i | u_x) p(u_x)}{\prod_i p(e^i | u_y) p(u_y)} \\ &= \frac{\prod_i \lambda_x^i p(u_x)}{\prod_i (1 - \lambda_y^i) p(u_y)} \end{aligned} \quad (15)$$

で与えられるから、事前確率が等しい ($p(u_x) = p(u_y)$) と仮定すれば、心証度は、

$$\frac{\prod_i \lambda_x^i}{\prod_i \lambda_x^i + \prod_i (1 - \lambda_y^i)}$$

となり、 $\lambda_x^i = \lambda_y^i$ ならば、ラプラスの式と一致する。

なる。
³⁶ 倉田(1969).

ここで、 $\lambda_x^i = \lambda_y^i$ というのは、当事者Xの主張する要証事実を前提として証拠的事実 e^i が導かれる確率 $p(e^i | u_x)$ と反対の要証事実を前提として反対の証拠的事実 e^i が得られる確率 $p(e^i | u_y)$ が等しいことを意味している。ラプラス³⁷が挙げた例でいうと、ある証人が（要証事実の真否によらず）真実の証言をする確率が0.9であるというのはこの場合にあたる。しかし、一般的には、両者が等しくなるとは限らないから、尤度をとったときに、ラプラスの式が成立するとは限らない。

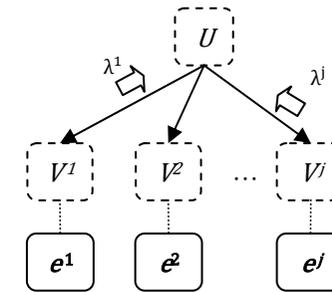


図13 ナীবベイズモデル

なお、 $\lambda_x^i \neq \lambda_y^i$ となる場合でも、ラプラスの式と同じ構造をした式を成り立たせることはできる。今、オッズが尤度の比となる数、つまり、

$$\frac{\varepsilon^i}{1 - \varepsilon^i} = \frac{\lambda_x^i}{\lambda_y^i} \quad (16)$$

となる、すなわち、

$$\varepsilon^i = \frac{\lambda_x^i}{\lambda_x^i + \lambda_y^i} \quad (17)$$

で定義される ε^i を用いれば、ラプラスの式と同じ形の式、すなわち、

$$p(u_x | e) = \frac{\prod \varepsilon^i}{\prod \varepsilon^i + \prod (1 - \varepsilon^i)} \quad (18)$$

³⁷ Laplace (1814).

が成立する。もっとも、 ε^i の値が経験などから直観的に得られるわけではないから、この ε を「経験則の確率」と呼ぶのが適切なかは疑問が残る。さらに言えば、ラプラスの式では、当該当事者にとって有利か不利かの基準は、1/2(50%)であり、0ではない。つまり、 ε^i が、0.5(50%)以上であれば、要証事実の心証度を高める一方、50%以下であれば弱めることになる(例えば、 ε^i が0.1(10%)であるというのは、単に、自己に有利な証拠にならないというだけでなく、より積極的に、自己に不利な証拠であることを意味する³⁸⁾から、 ε^i は「経験則の確率」というよりも、「証拠の証明力の偏差値」とでも呼ぶ方が適切であるように思われる。

なお、 ε^i から1/2を引き、2倍した値 d^i を考えれば、 d^i は、いずれの当事者の有利にも働かない場合の値が0、一方の当事者に最大限有利になる場合の数值を1(100%)となり、これは証拠の「証明力の強さ」を示していると理解できる³⁹⁾。このとき、

$$d^i := (\varepsilon^i - \frac{1}{2}) \times 2 = \frac{p(e^i | u_X) - p(e^i | u_Y)}{p(e^i | u_X) + p(\bar{e}^i | u_Y)} \quad (19)$$

となる。また、 d^i を用いると、ラプラスの式は、

$$p(u_X | e) = \frac{\prod d^i}{\prod d^i + \prod (1 + d^i)} \quad (20)$$

と表される。

7.4 因果関係の証明と間接反証

ルンバール事件(最判昭和50・10・24・民集29巻9号1417頁)に代表されるような、稀な結果から原因事実を確定し、因果関係を証明するという問題や間接反証の問題は、グラフィカルモデルを用いた確率的推論によって、必ずしも自明とは言えない結論を容易に導くことができる一例である。

例えば、結果 c (例えば、後遺障害)について、原因事実として $U = u_X$ (例えば、脳出血)と $V = v_Y$ (例えば、化膿性髄膜炎)という候補があり、 u_X も v_Y も生じて

いなければ、 c が生じることはあり得ない(あるいは、可能性が極めて低い)が、与えられた証拠 e^u だけでは、 u_X が生じる可能性が低いというケースを考える(図14)。

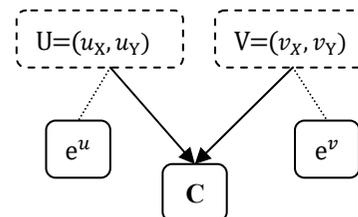


図14 原因の特定と因果関係

この場合、結果 c と与えられた他の証拠 $e = (e^u, e^v)$ のもとで、 u_X は生じた確率と u_X は生じていない(この場合、 v_Y が生じていなければならない)確率の比(オッズ)は、

$$\begin{aligned} \frac{p(u_X | e, c)}{p(u_Y, v_Y | e, c)} &= \frac{p(u_X | e^u)p(c | u_X)}{p(u_Y | e^u)p(v_Y | e^u)p(c | u_Y, v_Y)} \\ &\approx \frac{p(u_X | e^u)p(c | u_X)}{p(v_Y | e^u)p(c | v_Y)} \end{aligned} \quad (21)$$

となる。したがって、 $p(c | u_X) \approx p(c | v_Y)$ であれば、 $p(u_X | e^u)$ の絶対値は小さくても、 $p(u_X | e^u) \gg p(v_Y | e^u)$ 、すなわち、与えられた証拠からすれば、 v_Y が生じた蓋然性は、抽象的なものにとどまる一方、これと比べると、 u_X が生じた蓋然性は具体的で、相対的に見れば著しく大きい場合には、オッズが非常に大きくなる、つまり、心証度は十分高くなる⁴⁰⁾。

したがって、原因となる事実 u_X が生じた可能性が具体的に一定程度あることを示

³⁸⁾ 太田(1982)p.96.

³⁹⁾ ある供述に信用性がないというのは、一般には、 $d^i \approx 0$ (つまり、 $\varepsilon^i \approx 50\%$)の場合であり、 $d^i \approx -1$ ($\varepsilon^i \approx 0\%$)の場合ではない。

⁴⁰⁾ 例えば、 u_X が生じた可能性が5%、 v_Y が生じた可能性が0.05%とすると、尤度比は100、すなわち、心証度が99%を超えることになる。また、 $p(c | u_X) < p(c | v_Y)$ であっても、 $p(u_X | e^u) \gg p(v_Y | e^u)$ であれば、同様に心証度は高くなりうる。

し、他の原因 v_Y による可能性があくまでも抽象的なものにとどまる限りにおいては、原因が u_X であることについて高度の蓋然性をもって証明がなされたことになり、反対当事者としては、 v_Y が生じた可能性も相当程度あることについて、具体的な反証をしなければならないことになる。

8. 結語

裁判における事実認定においては、心証度についての正確な値を求める必要はないから、事実認定において確率的推論を行うにおいても、「確率を正確に測定できないから、確率的推論を現実の事案に用いることができない」という批判はあてはまらない。「確率論の本質は、数値計算ではなく推論の構造である ("Probability is not really about numbers; it is about the structure of reasoning.")」というShaferの指摘⁴¹は、事実認定においても完全に当てはまる。グラフィカルモデルは、推論を、必要に応じて単純化したり、精緻化したりしながら、その構造を視覚化することができるという点で優れた特質を有しており、事実認定の客観化を図る上で法律家にとって不可欠のツールとなりうる。そのためにも、具体的な事案の分析を通じて、推論の方法を考究していくことが今後求められる。

判例

最判昭28.9.25 (1953) 民集第7巻9号979頁.

最判昭50.10.24 (1975) 民集29巻9号1417頁.

最判昭61.10.2 (1986) 労判485号12頁.

最判昭61.10.7 (1986) 労判485号6頁.

最判平6.5.16 (1994) 集民第172号509頁.

最判平8.1.23 (1996) 集民第178号83頁.

最判平9.11.28 (1997) 集民第186号269頁.

最判平18.6.16 (2006) 民集第60巻5号1997頁.

最判平22.4.27 (2010) 刑集第64巻3号233頁

参考文献

太田勝造 (1982) 『裁判における証明論の基礎』弘文堂.

木本茂樹 (2015) 「事実認定における真実の発見を目的としない諸法理のベイズ論的モデル」, 2015年度(第13回)法と経済学会全国大会研究発表,
http://www.jlea.jp/2015zy_zr/ZR15-13.pdf

草野耕一 (2014) 「『検察官の誤謬』と『弁護人の誤謬』」論究ジュリスト2014夏号(10号), 20-29.

倉田卓次 (1969) 「交通事故訴訟における事実の証明度」鈴木忠一・三ヶ月章(監修)『実務民事訴訟講座(3) 交通事故訴訟』日本評論社, 101-137.

Bishop, C.M., (2006) *Pattern Recognition and Machine Learning*, Springer. (元田 浩ほか監訳 (2007) 『パターン認識と機械学習 上 - ベイズ理論による統計的予測』丸善出版)

Cox, R.T. (1961) *the Algebra of Probable Inference*, Baltimore, the Johns Hopkins Press.

Darwiche, A. (2009) *Modeling and Reasoning with Bayesian Networks*, Cambridge, Cambridge University Press.

Fenton, N., Neil, M. and Lagnado, D. (2012) "A General Structure for Legal Arguments about Evidence Using Bayesian Networks," *Cognitive Science* 2012, pp.1-42.

Fenton, N. and Neil, M. (2013) *Risk Assessment and Decision Analysis with Bayesian Networks*, Boca Raton, CRC Press.

Finkelstein, M.O., and Fairley, W.B. (1970) "A Bayesian Approach to Identification Evidence," 83 *Harvard Law Review*, 489-517.

Friedman, R.D. (1986) "A Diagrammatic Approach to Evidence," *Boston University Law Review*, No.66, 571-633.

Jaynes, E.T. (2003) *Probability, The Logic of Science*, Cambridge, Cambridge University

⁴¹ Glenn ShaferのJudea Pearlへの私信. Pearl (1988) p.15からの再引用.

Press.

Kadane, J.B. and Schum, D. (1996) *A Probabilistic Analysis of Vanzetti Evidence*, New York, Wiley.

Keynes, J.M., (1921) *A Treatise on Probability*, London, Macmillan. (佐藤隆三訳 (2010)『確率論』東洋経済新報社.)

Laplace, P., (1814) *Essai Philosophique sur les Probabilités*, Paris, V^oe Courcier. (樋口順四郎 (抄訳) (1977) 「確率についての哲学的試論」湯川秀樹・井上健責任編集『世界の名著65』中央公論社.)

Pearl, J. (1988) *Probabilistic Reasoning in Intelligent Systems*, San Francisco, Morgan Kaufmann Publishers.

Pearl, J. (2000) *Causality: Models, Reasoning, and Inference*, Cambridge, Cambridge University Press. (黒木学 (訳) (2009)『統計的因果推論』共立出版.)

Taroni, F., Aitken, C., Garbolino, P. and Biedermann, A.I. (2006) *Bayesian Network and Probabilistic Inference in Forensic Science*, Wiltshire, John Wiley & Sons.

Verheij, B., Bex, B., Timmer, S., Vlek, C., Meyerb, J., Renooij, S., Prakken, H. (2016) “Arguments, scenarios and probabilities: connections between three normative frameworks for evidential reasoning,” *Law, Probability & Risk* 15, 35-70.

Vlek, C., Prakken, H., Renooij, S., and Verheij, B., (2016) “A Method for Explaining Bayesian Networks for Legal Evidence with Scenarios,” *Artificial Intelligence and Law* 24, 1-40.

Wigmore, J. H. (1913) "The problem of proof," *Illinois Law Review* 8 (2), 77-103.

- (1937). *The Science of Proof: As Given by Logic, Psychology and General Experience and Illustrated in Judicial Trials* (3rd ed.). Boston: Little, Brown.