

第 8 章「統計的推測」

1 . 統計的決定理論 (Statistical Decision Theory)

A. Wald により 1940 年代に体系化された , ゲーム理論の観点からの統計的推測理論 .

標本空間 \mathcal{X} (Sample Space) :

確率変数の実現値 (観測値) からなる集まり

行動空間 \mathcal{A} (Action Space) :

分析者が取りうる行動の全体

決定空間 \mathcal{D} (Decision Space) :

標本空間から行動空間への関数である決定関数 $\delta(x) : \mathcal{X} \rightarrow \mathcal{A}$ の全体

母数空間 Θ (Parameter Space) :

パラメータが取りうる値の全体

・ 損失関数 (Loss Function)

パラメータ θ に対して , 行動 a を取るときの損失を表す .

$$w(\theta, a) : \Theta \times \mathcal{A} \rightarrow \mathcal{R}$$

・ 危険関数 (Risk Function)

$$r(\theta, \delta) = E[w(\theta, \delta(\mathbf{X}))] = \int w(\theta, \delta(\mathbf{x})) f_n(\mathbf{x}|\theta) d\mathbf{x}$$

2 . 推定理論 (Estimation Theory)

この場合の行動は , パラメータを推定することだから , 行動空間 = 母数空間 . また , 決定関数 $T_n : \mathcal{X} \rightarrow \Theta$ は推定量 (estimator) と呼ばれる .

$$w(\theta, T_n) = (T_n - \theta)^2$$

$$r(\theta, T_n) = E(|T_n(\mathbf{X}) - \theta|^2) = \int |T_n(\mathbf{x}) - \theta|^2 f_n(\mathbf{x}|\theta) d\mathbf{x}$$

$$E(T_n(\mathbf{X})) = \theta \quad : \text{不偏推定量 (unbiased estimator)}$$

$$b(\theta) = E(T_n(\mathbf{X})) - \theta \quad : \text{偏り (bias)}$$

クラメル・ラオの定理

不偏推定量 T_n の分散は , 密度関数に関する適当な正則条件のもとで , 次の下限をもつ .

$$V(T_n) \geq \frac{1}{I_n(\theta)} = \frac{1}{n I_1(\theta)}$$

ここで, $I_n(\theta)$ はサイズ n の標本に基づくフィッシャー情報量であり, 等号は, 微分方程式

$$\frac{d \log f_n(\mathbf{x}|\theta)}{d\theta} = I_n(\theta) (T_n - \theta)$$

をみたすときに成り立つ.

証明 まず, 次のことが成り立つ.

$$E \left(\frac{d \log f_n(\mathbf{x}|\theta)}{d\theta} \right) = 0, \quad Cov \left(T_n, \frac{d \log f_n(\mathbf{x}|\theta)}{d\theta} \right) = 1$$

したがって, コーシー・シュワルツの不等式から,

$$1 = Cov^2 \left(T_n, \frac{d \log f_n(\mathbf{x}|\theta)}{d\theta} \right) \leq V(T_n) V \left(\frac{d \log f_n(\mathbf{x}|\theta)}{d\theta} \right) = V(T_n) I_n(\theta)$$

となるから, 定理の不等式が証明される. 等号は,

$$\frac{d \log f_n(\mathbf{x}|\theta)}{d\theta} = a + b T_n$$

のとき成り立つから, 両辺の期待値を取ると

$$0 = a + b\theta \quad \Leftrightarrow \quad a = -b\theta \quad \Leftrightarrow \quad \frac{d \log f_n(\mathbf{x}|\theta)}{d\theta} = b(T_n - \theta)$$

となる. これから,

$$1 = Cov \left(\frac{d \log f_n(\mathbf{x}|\theta)}{d\theta}, T_n \right) = b V(T_n) = \frac{b}{I_n(\theta)}$$

を得るので, $b = I_n(\theta)$ となり, 定理は証明された.

有効推定量 (Efficient Estimator) クラメル・ラオの不等式の下限を達成するような推定量を有効推定量という.

例1 $X \sim B(n, p)$ のとき, \bar{X} は p の有効推定量である. 実際, $E(\bar{X}) = p$, $V(\bar{X}) = p(1-p)/n$ であり, また,

$$\log f_n(X|p) = \log_n C_X + X \log p + (n - X) \log(1 - p)$$

であるから,

$$\frac{d \log f}{dp} = \frac{X}{p} - \frac{n - X}{1 - p} = \frac{X - np}{p(1 - p)}$$

となり, フィッシャー情報量 $I_n(p)$ は $n/(p(1-p))$ となる. この逆数は, $V(\bar{X})$ であるから, \bar{X} は有効推定量である. なお,

$$\frac{d \log f}{dp} = \frac{X - np}{p(1 - p)} = \frac{n}{p(1 - p)} (\bar{X} - p) = I_n(p) (\bar{X} - p)$$

が成り立つことから, 有効性がいえる.

例2 X_1, \dots, X_n は $N(\mu, 1)$ からのランダム標本であるとする。このとき, \bar{X} は μ の有効推定量である。実際, $V(\bar{X}) = 1/n$, $I_n(\mu) = n$ となる。

一様最小分散不偏推定量 (UMVUE) θ の不偏推定量 $\hat{\theta}$ の分散が, 他のいかなる不偏推定量の分散よりも θ に関して一様に小さいとき, $\hat{\theta}$ は UMVUE であるという。

例 X_1, \dots, X_n が平均 μ , 分散 σ^2 の独立, 同一分布に従うとき, μ の推定量のクラスを X_1, \dots, X_n の線形関数に限れば, \bar{X} は UMVUE となる。実際,

$$\tilde{\mu} = c_1 X_1 + \dots + c_n X_n$$

が不偏であることから, $c_1 + \dots + c_n = 1$ であり,

$$V(\tilde{\mu}) = \sum_{i=1}^n c_i^2 \sigma^2 = \sum_{i=1}^n (c_i - 1/n + 1/n)^2 \sigma^2 = \sum_{i=1}^n (c_i - 1/n)^2 \sigma^2 + \sigma^2/n$$

となることから, $c_i = 1/n$ ($i = 1, \dots, n$) のとき, 最小の分散をもつ。

・有効推定量と UMVUE との関係

有効推定量ならば UMVUE であるが, 逆は必ずしもいえない。例えば, 正規母集団 $N(\mu, \sigma^2)$ からのランダム標本 X_1, \dots, X_n に対して, $S^2 = \sum_{i=1}^n (X_i - \bar{X})^2 / (n-1)$ は σ^2 の UMVUE であるが, 有効ではない。

3. 検定理論 (Testing Theory)

行動空間は, $\mathcal{A} = \{a_0, a_1\}$ であり,

a_0 : 帰無仮説 H_0 を受容する行動

a_1 : 帰無仮説 H_0 を棄却する行動

決定関数 δ には棄却域と受容域が対応する。

$$W = \{\mathbf{x} : \delta(\mathbf{x}) = a_1\} \quad \text{棄却域}$$

$$W^c = \{\mathbf{x} : \delta(\mathbf{x}) = a_0\} \quad \text{受容域}$$

・第1種の誤りと第2種の誤り

パラメータ θ は, 帰無仮説のもとで θ_0 , 対立仮説のもとで θ_1 の値を取るものとする。このとき,

第1種の誤りの確率:

$$\alpha = r(\theta_0, \delta) = \int_{\mathcal{X}} w(\theta_0, \delta(\mathbf{x})) f_n(\mathbf{x}|\theta_0) d\mathbf{x} = \int_W f_n(\mathbf{x}|\theta_0) d\mathbf{x}$$

第2種の誤りの確率:

$$\beta = r(\theta_1, \delta) = \int_{\mathcal{X}} w(\theta_1, \delta(\mathbf{x})) f_n(\mathbf{x}|\theta_1) d\mathbf{x} = \int_{W^c} f_n(\mathbf{x}|\theta_1) d\mathbf{x}$$

ここで, w は次のように定義される損失関数である。

$$w(\theta_0, \delta(\mathbf{x})) = \begin{cases} 1 & (\delta(\mathbf{x}) = a_1) \\ 0 & (\delta(\mathbf{x}) = a_0) \end{cases} \quad w(\theta_1, \delta(\mathbf{x})) = \begin{cases} 1 & (\delta(\mathbf{x}) = a_0) \\ 0 & (\delta(\mathbf{x}) = a_1) \end{cases}$$

・検定関数 (Test function)

$$\phi(\mathbf{x}) = \begin{cases} 1 & (\mathbf{x} \in W) \\ 0 & (\mathbf{x} \in W^c) \end{cases}$$

このとき,

$$\alpha = \int_{\mathcal{X}} \phi(\mathbf{x}) f_n(\mathbf{x}|\theta_0) d\mathbf{x}, \quad \beta = \int_{\mathcal{X}} \{1 - \phi(\mathbf{x})\} f_n(\mathbf{x}|\theta_1) d\mathbf{x}$$

・検出力 (Power)

$$= 1 - \beta \quad (1 \text{ から第 2 種の誤りの確率をひいたもの)$$

・Neyman-Pearson's fundamental lemma

有意水準を α とする (= 第 1 種の誤りの確率を α 以下とする) とき, 最強力検定は

$$\phi^*(x) = \begin{cases} 1 & (f_n(\mathbf{x}|\theta_1)/f_n(\mathbf{x}|\theta_0) > k) \\ 0 & (f_n(\mathbf{x}|\theta_1)/f_n(\mathbf{x}|\theta_0) < k) \\ p & (f_n(\mathbf{x}|\theta_1)/f_n(\mathbf{x}|\theta_0) = k) \end{cases}$$

で与えられる. ここで, 定数 k と確率 p は,

$$\int \phi^*(\mathbf{x}) f_n(\mathbf{x}|\theta_0) d\mathbf{x} = \alpha$$

をみたすように決められる.

証明 有意水準 α の任意の検定を ϕ とするとき,

$$\begin{aligned} \int \phi(\mathbf{x}) f_n(\mathbf{x}|\theta_1) d\mathbf{x} - k\alpha &\leq \int \phi(\mathbf{x}) f_n(\mathbf{x}|\theta_1) d\mathbf{x} - k \int \phi(\mathbf{x}) f_n(\mathbf{x}|\theta_0) d\mathbf{x} \\ &= \int \phi(\mathbf{x}) (f_n(\mathbf{x}|\theta_1) - k f_n(\mathbf{x}|\theta_0)) d\mathbf{x} \\ &\leq \int \phi^*(\mathbf{x}) (f_n(\mathbf{x}|\theta_1) - k f_n(\mathbf{x}|\theta_0)) d\mathbf{x} \\ &= \int \phi^*(\mathbf{x}) f_n(\mathbf{x}|\theta_1) d\mathbf{x} - k\alpha \end{aligned}$$

となる. したがって,

$$\int \phi^*(\mathbf{x}) f_n(\mathbf{x}|\theta_1) d\mathbf{x} \geq \int \phi(\mathbf{x}) f_n(\mathbf{x}|\theta_1) d\mathbf{x}$$

となり, 証明された.

(注) $\phi^*(\mathbf{x}) = p$ (確率 p で帰無仮説を棄却) が必要なのは離散的な場合であり, 上の証明の中で最後の等号を保証するものである.

例 1 X_1, \dots, X_n を $N(\mu, \sigma^2)$ からのランダム標本とする. ただし, σ^2 は既知として, 検定問題

$$H_0: \mu = \mu_0 \quad \text{vs.} \quad H_1: \mu = \mu_1 (> \mu_0)$$

を考える．このとき，

$$f_n(\mathbf{x}|\mu) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right\}$$

より，

$$\frac{f_n(\mathbf{x}|\mu_1)}{f_n(\mathbf{x}|\mu_0)} = \exp\left[\frac{\mu_1 - \mu_0}{\sigma^2} \sum_{i=1}^n \left(x_i - \frac{\mu_0 + \mu_1}{2}\right)\right] > k \Leftrightarrow \bar{x} > k'$$

有意点 k' は，与えられた有意水準 α に対して，

$$\begin{aligned} \alpha &= P(\bar{X} > k' | \mu_0) \\ &= P\left(\frac{\sqrt{n}(\bar{X} - \mu_0)}{\sigma} > \frac{\sqrt{n}(k' - \mu_0)}{\sigma} \middle| \mu_0\right) = P\left(\frac{\sqrt{n}(\bar{X} - \mu_0)}{\sigma} > z_\alpha \middle| \mu_0\right) \end{aligned}$$

と標準化することによって求められる． z_α は $N(0, 1)$ の上側 $100\alpha\%$ 点である．したがって，最強力検定の棄却域は

$$W = \left\{ \bar{x} > \mu_0 + z_\alpha \frac{\sigma}{\sqrt{n}} \right\}$$

となる．検出力は，

$$\begin{aligned} 1 - \beta &= P\left(\bar{X} > \mu_0 + z_\alpha \frac{\sigma}{\sqrt{n}} \middle| \mu_1\right) \\ &= P\left(\frac{\sqrt{n}(\bar{X} - \mu_1)}{\sigma} > z_\alpha - \frac{\sqrt{n}(\mu_1 - \mu_0)}{\sigma} \middle| \mu_1\right) \end{aligned}$$

となり， $\mu_1 \rightarrow \infty$ のとき，1 に近づく．

数値例 あるメーカーの従来の電球の寿命は平均 1,500 時間，標準偏差 200 時間の正規分布に従うとする．新製品は標準偏差は従来通りであるが，平均は 10 % アップして，1,650 時間であると言われている．このことを有意水準 5 % で検定したい．標本サイズが 10 のとき，最強力検定の棄却域と検出力は次のようになる．

棄却域は，

$$\bar{x} > \mu_0 + z_\alpha \frac{\sigma}{\sqrt{n}} = 1500 + 1.645 \times \frac{200}{\sqrt{10}} = 1604$$

検出力は，

$$P(\bar{X} > 1604 | \mu_1 = 1650) = P\left(Z > \frac{\sqrt{10}(1604 - 1650)}{200}\right) = P(Z > -0.7273) = 0.7664$$

例 2 X_1, \dots, X_n はポアソン分布 $Po(\lambda)$ に従うランダム標本であるとして，検定問題

$$H_0 : \lambda = \lambda_0 \quad \text{vs.} \quad H_1 : \lambda = \lambda_1 (< \lambda_0)$$

を考える .

$$f_n(\mathbf{x}|\lambda) = \prod_{i=1}^n \frac{\exp(-\lambda) \lambda^{x_i}}{x_i!} = \exp(-n\lambda) \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!}$$

であるから , 最強力検定の棄却域は

$$\frac{f_n(\mathbf{x}|\lambda_1)}{f_n(\mathbf{x}|\lambda_0)} = \exp(n(\lambda_0 - \lambda_1)) \prod_{i=1}^n \left(\frac{\lambda_1}{\lambda_0}\right)^{x_i} > k \quad \Leftrightarrow \quad S_n = \sum_{i=1}^n x_i < k'$$

となる . ここで , $S_n \sim Po(n\lambda)$ である . この場合の検定は , 一般に確率化検定となる . 例えば , 有意水準 $\alpha = 0.1$, $n\lambda_0 = 3$ のとき ,

$$P(S_n = 0 | n\lambda_0 = 3) = e^{-3} = 0.05, \quad P(S_n = 1 | n\lambda_0 = 3) = 3e^{-3} = 0.15$$

であるから , $S_n = 0$ を棄却域とすれば検定のサイズは 0.05 . また , $S_n = 0, 1$ を棄却域とすれば検定のサイズは 0.2 となってしまう . そこで , $S_n = 0$ のときには常に棄却 , $S_n = 1$ のときには確率 $1/3$ で棄却する確率化検定を考えれば , そのサイズは

$$P(S_n = 0 | n\lambda_0 = 3) + \frac{1}{3} \times P(S_n = 1 | n\lambda_0 = 3) = e^{-3} + \frac{1}{3} \times 3 \times e^{-3} = 0.1$$

となる . 検出力は , 例えば , $n\lambda_1 = 2$ に対しては ,

$$P(S_n = 0 | n\lambda_1 = 2) + \frac{1}{3} \times P(S_n = 1 | n\lambda_1 = 2) = e^{-2} + \frac{1}{3} \times 2 \times e^{-2} = 0.23$$

4 . 回帰理論 (Regression Theory)

2 つの確率変数 X と Y があるとき , Y の値を X の関数 $\hat{Y} = h(X)$ によって推定することを , Y を X に回帰するといいい , $h(X)$ を回帰関数 (regression function) という . この場合 , 行動空間 $\mathcal{A} =$ 標本空間 \mathcal{X} , 決定関数 $\delta(X) = h(X)$ である . 損失関数を 2 乗誤差で定義すると , 危険関数は

$$r(h) = E[(Y - h(X))^2] = \int \int (y - h(x))^2 f(x, y) dx dy$$

となる .

定理 上のリスクを最小にする $h(X)$ は ,

$$h^*(X) = E[Y|X]$$

である .

証明

$$\begin{aligned} E[(Y - h(X))^2] &= E[\{Y - E(Y|X) - (h(X) - E(Y|X))\}^2] \\ &= E[(Y - E(Y|X))^2] + E[(h(X) - E(Y|X))^2] \\ &\quad + 2E[(Y - E(Y|X))(h(X) - E(Y|X))] \end{aligned}$$

において , 最後の項は , 期待値の繰り返しの公式を使えば 0 になることがわかる . したがって , リスクは $h(X) = E(Y|X)$ のとき最小となる .

・最良線形回帰 (Best Linear Regression)

条件付き期待値の計算が困難な場合，線形回帰 $Y_L = a + bX$ のクラスでリスクを最小にするものを考えることが多い．それは，

$$a = E(Y) - bE(X), \quad b = Cov(X, Y)/V(X) = \rho_{XY}\sqrt{V(Y)/V(X)}$$

で与えられる．

例 確率変数 X と Y の同時密度関数が

$$f(x, y) = 2(x + 2y)/3 \quad (0 \leq x \leq 1, 0 \leq y \leq 1)$$

であたえられているとき，最良回帰と最良線形回帰を求めよう．まず，

$$f_1(x) = \int_0^1 f(x, y) dy = 2(x + 1)/3$$

$$f_2(y|x) = f(x, y)/f_1(x) = (x + 2y)/(x + 1)$$

であるから，最良回帰は

$$E(Y|X) = \int_0^1 y f_2(y|x) dy = (3x + 4)/(6x + 6)$$

となる．このときのリスクは $E(V(Y|X))$ であるが，

$$V(Y|X) = E(Y^2|X) - E^2(Y|X) = \frac{1}{12} - \frac{1}{36(x + 1)^2}$$

となることから，

$$E(V(Y|X)) = \frac{1}{12} - \frac{\log 2}{54} = 0.07049727$$

を得る．他方，最良線形回帰は，

$$E(X) = 5/9, \quad E(Y) = 11/18, \quad V(X) = 13/162, \quad V(Y) = 23/324,$$

$$Cov(X, Y) = -1/162, \quad \rho_{XY} = -\sqrt{2/299}$$

を使って， $b = Cov(X, Y)/V(X) = -1/13$ ， $a = E(Y) - bE(X) = 17/26$ を得るから，

$$Y_L^* = \frac{17 - 2x}{26}$$

となる．このときのリスクは，

$$V(Y)(1 - \rho_{XY}^2) = \frac{23}{324} \left(1 - \frac{2}{299}\right) = 0.07051282$$

となる．

5．ベイズ解とミニマックス解

・ベイズ解

パラメータ θ が確率変数の実現値であるという立場に立つとき、 θ として実現する前の分布（事前分布）として $\pi(\theta)$ を考えることができる。このとき、リスクの事前分布に関する期待値

$$r_B(\delta) = \int r(\theta, \delta) \pi(\theta) d\theta$$

をベイズ・リスクといい、ベイズ・リスクを最小にするような決定関数、すなわち

$$r_B(\delta_B) = \min\{r_B(\delta) : \delta \in \mathcal{D}\}$$

もみたす δ_B をベイズ解という。

・事後分布と事後危険（Posterior Distribution and Risk）

$f_n(\mathbf{x}, \theta) = \pi(\theta) f_n(\mathbf{x}|\theta)$ を \mathbf{x} と θ の同時密度関数とすると、

$$\pi(\theta|\mathbf{x}) = \frac{f_n(\mathbf{x}, \theta)}{\int f_n(\mathbf{x}, \theta) d\theta}$$

を、 θ の事後分布という。損失関数の事後分布による期待値

$$r(\delta(\mathbf{x})|\mathbf{x}) = \int w(\theta, \delta(\mathbf{x})) \pi(\theta|\mathbf{x}) d\theta$$

を $\delta(\mathbf{x})$ の事後リスクという。事後リスクは $X = \mathbf{x}$ の関数であるが、ここでさらに X の分布に関する期待値をとれば、

$$\begin{aligned} \int r(\delta(\mathbf{x})|\mathbf{x}) f_n(\mathbf{x}) d\mathbf{x} &= \int \int w(\theta, \delta(\mathbf{x})) \pi(\theta|\mathbf{x}) f_n(\mathbf{x}) d\theta d\mathbf{x} \\ &= \int \int w(\theta, \delta(\mathbf{x})) \frac{\pi(\theta) f_n(\mathbf{x}|\theta)}{f_n(\mathbf{x})} f_n(\mathbf{x}) d\theta d\mathbf{x} \\ &= \int r(\theta, \delta) \pi(\theta) d\theta \\ &= r_B(\delta) \end{aligned}$$

となる。すなわち、事後リスクの期待値はベイズ・リスクである。このことから、次の定理が成立する。

定理 事後リスクを最小にする決定関数 δ^* はベイズ解である。

証明 任意の決定関数に対して、

$$r(\delta(\mathbf{x})|\mathbf{x}) \geq r(\delta^*(\mathbf{x})|\mathbf{x})$$

が成り立つから、両辺を X の分布に関して平均すれば $r_B(\delta) \geq r_B(\delta^*)$ を得る。

定理 損失関数が 2 乗誤差 $w(\theta, T) = (T - \theta)^2$ で与えられるとき、ベイズ解は事後平均

$$E(\theta|\mathbf{x}) = \int \theta \pi(\theta|\mathbf{x}) d\theta$$

で与えられる。

証明 この場合の事後リスクは、

$$r(T(\mathbf{x})|\mathbf{x}) = \int (\theta - T(\mathbf{x}))^2 \pi(\theta|\mathbf{x}) d\theta$$

であり，これを最小にする $T(\mathbf{x}) = E(\theta|\mathbf{x})$ ，すなわち事後平均である．

・ミニマックス解 リスク $r(\theta, \delta)$ の θ に関する最大値を最小とするような決定関数 δ_M をミニマックス解という．すなわち，

$$r_M(\delta_M) = \min_{\delta} \max_{\theta} r(\theta, \delta)$$

定理 ある事前分布 π に対して，ベイズ解 δ_B のリスク $r(\theta, \delta_B)$ が定数 (θ に無関係) ならば， δ_B はミニマックス解である．

証明 δ_B のリスク $r(\theta, \delta_B)$ が定数で，事前分布 π に対するベイズ解ならば，

$$\min_{\delta} \int r(\theta, \delta) \pi(\theta) d\theta = \int r(\theta, \delta_B) \pi(\theta) d\theta = c$$

明らかに，

$$\max_{\theta} r(\theta, \delta) \geq \int r(\theta, \delta) \pi(\theta) d\theta$$

であるから，

$$\min_{\delta} \max_{\theta} r(\theta, \delta) \geq \min_{\delta} \int r(\theta, \delta) \pi(\theta) d\theta = c$$

他方， δ_B のリスクは θ に無関係な定数 c であることから，

$$c = \max_{\theta} r(\theta, \delta_B) \geq \min_{\delta} \max_{\theta} r(\theta, \delta)$$

以上から，

$$\max_{\theta} r(\theta, \delta_B) = \min_{\delta} \max_{\theta} r(\theta, \delta) = c$$

となり， δ_B はミニマックス解となる．

例 成功の確率 p を推定するために， n 回の独立なベルヌーイ試行 X_1, \dots, X_n を行うとき (各 X_i が取る値は $0, 1$)，尤度関数は

$$f_n(\mathbf{x}|p) = p^x (1-p)^{n-x}, \quad x = \sum_{i=1}^n x_i$$

である．推定量 \bar{X} は不偏であり，2乗誤差を損失関数とするととき，リスクは

$$r(p, \bar{X}) = \frac{p(1-p)}{n}$$

である．次に，ベイズ解を考えよう． p の事前分布を

$$\pi(p) = B(\alpha, \beta)^{-1} p^{\alpha-1} (1-p)^{\beta-1}$$

とするととき， (\mathbf{x}, p) の同時分布は，

$$f_n(\mathbf{x}, p) = B(\alpha, \beta)^{-1} p^{x+\alpha-1} (1-p)^{n-x+\beta-1}$$

となる。したがって、 x の周辺密度は、

$$f_n(\mathbf{x}) = \int f_n(\mathbf{x}, p) dp = \frac{B(x + \alpha, n - x + \beta)}{B(\alpha, \beta)}$$

となる。また、 p の事後分布は

$$\pi(p|\mathbf{x}) = \frac{f_n(\mathbf{x}, p)}{f_n(\mathbf{x})} = B(x + \alpha, n - x + \beta)^{-1} p^{x+\alpha-1} (1-p)^{n-x+\beta-1}$$

となる。すなわち、 p の事前分布 = $B_E(\alpha, \beta)$ は事後分布 = $B_E(x + \alpha, n - x + \beta)$ となる。2乗誤差を損失関数とする場合、ベイズ推定量 (ベイズ解) は事後分布 $B_E(x + \alpha, n - x + \beta)$ の平均

$$T_B = \frac{x + \alpha}{n + \alpha + \beta} = \frac{\bar{x} + \frac{\alpha}{n}}{1 + \frac{\alpha + \beta}{n}}$$

であり、そのリスクは、 $X = \sum_{i=1}^n X_i \sim B(n, p)$ であることから、

$$\begin{aligned} E(T_B - p)^2 &= E\left(\frac{X + \alpha}{n + \alpha + \beta} - p\right)^2 \\ &= \frac{((\alpha + \beta)^2 - n)p^2 + (n - 2\alpha(\alpha + \beta))p + \alpha^2}{(n + \alpha + \beta)^2} \end{aligned}$$

となる。ここで、 $\alpha = \beta = \sqrt{n}/2$ (= 事前分布が $B_E(\sqrt{n}/2, \sqrt{n}/2)$) ならば、ベイズ解のリスクは定数となるから、このときはミニマックス解でもある。