

第9章 Bayes 的推測

9.1 Bayes 的推測の考え方

前節までの統計的手法は頻度論的手法 (frequentist methods) と呼ばれるものである。頻度論的アプローチの考え方は以下のようにまとめられる。

- 【F1】 確率は大量に観測されたデータの度数の極限と考える。
- 【F2】 真の母数は未知だが、固定した値であると考え。したがって真の母数は変動しないし、真の母数に対する意味のある確率的な主張はない。
- 【F3】 推測手法は大量にデータが観測されれば、うまく機能する保証があるように設計されている。たとえば信頼係数 0.95 の信頼区間は、大量に観測されたデータの極限的な頻度において、0.95 の信頼度が保証されている。

この考え方とは異なるアプローチの 1 つが Bayes 的推測である。Bayes 的アプローチは以下のような考え方に基づいている。

- 【B1】 確率は極限的な頻度ではなく、信頼の程度を表現するものであると考える。データはある確率変数の実現値と考えるだけでなく、それ以外の色々なものも確率変数の実現値と考える。
- 【B2】 真の母数は固定された定数にも関わらず、真の母数の確率的な主張をする。
- 【B3】 真の母数に対して確率分布を想定し、未知の母数の推測を行う。点推定値や区間推定値もこの分布からの実現値と考える。

確率に主観的な見方を導入する Bayes 的アプローチには、頻度論的立場の主流派 (古典的な) 統計学者からの大きな批判がある。しかし、統計学の隣接分野である機械学習やデータマイニングの分野では Bayes 的なアプローチが広く採用されている。

哲学的な議論は脇において、Bayes 的推測がどのような形式で行われるかをこの節ではみていく。

9.2 Bayes 的推測手法

Bayes 的推測は以下のステップに従い行われる. 母数モデルを $\{P_\theta; \theta \in \Theta\}$ とする.

1. 事前分布 (prior distribution) と呼ばれる母数 θ についての分布 $\pi(\theta)$ を想定する.
2. 母数 θ に与えられたときにデータの分布を表現する条件付きの分布 (頻度論的な立場では真の分布) $p^X(x|\theta)$ を想定する.
3. 観測されたデータ $X_1 = x_1, X_2 = x_2, \dots, X_n = x_n$ に基づき, θ の信頼度をアップデートする. すなわち, 事後分布 (posterior distribution) $\pi_{\theta|X}(\theta|\mathbf{x})$ を求める. ただし $\mathbf{x} = (x_1, x_2, \dots, x_n)$ とした.

そして, 事後分布に基づき, 母数の推測を行う. 3 番目のステップがどのように行われるかを θ の事前分布とデータ X の分布が共に離散型の場合で説明する.

真の母数 θ は確率変数 Θ の実現値と考える. いまは離散型確率変数の設定なので

$$\begin{aligned} \Pr(\Theta = \theta | \mathbf{X} = \mathbf{x}) &= \frac{\Pr(\Theta = \theta, \mathbf{X} = \mathbf{x})}{\Pr(\mathbf{X} = \mathbf{x})} \\ &= \frac{\Pr(\Theta = \theta, \mathbf{X} = \mathbf{x})}{\sum_{\theta} \Pr(\mathbf{X} = \mathbf{x} | \Theta = \theta) \Pr(\Theta = \theta)} \end{aligned}$$

となる. 最後の等号は全確率の法則 (補題 1.11) を用いた. これを連続型分布の場合に形式的に書き直すと

$$\pi_{\Theta|X}(\theta|\mathbf{x}) = \frac{p^X(\mathbf{x}|\theta)\pi(\theta)}{\int p^X(\mathbf{x}|\theta)\pi(\theta) d\theta}$$

と書ける. ただし $\pi_{\Theta|X}(\cdot|\mathbf{x})$ は $X = \mathbf{x}$ が与えられたときの Θ の条件付き p.d.f. であり, θ の事後分布である. $p(\mathbf{x}|\theta)$ は真の母数が θ のときのデータの分布の p.d.f. で, $\pi(\theta)$ は Θ の分布の p.d.f. である.

n 個のランダム標本 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ に対して, 真の母数が θ のときの X の同時 p.d.f. $p^X(\cdot|\theta)$ とし, $X_1 = x_1, X_2 = x_2, \dots, X_n = x_n$ を観測したときの尤度関数 $\text{lik}_n(\theta)$ を

$$\text{lik}_n(\theta) = p^X(\mathbf{x}|\theta)$$

と書くことにする. よって

$$\pi_{\Theta|X}(\theta|\mathbf{x}) = \frac{p^X(\mathbf{x}|\theta)\pi(\theta)}{\int p^X(\mathbf{x}|\theta)\pi(\theta) d\theta} =: \frac{\text{lik}_n(\theta)\pi(\theta)}{c_n} \propto \text{lik}_n(\theta)\pi(\theta)$$

と表すことができる. ただし

$$c_n := \int \text{lik}_n(\theta)\pi(\theta) d\theta$$

は正規化定数と呼ばれる値である. c_n は θ に依存せず, データの実現値に依存した値である. よって事後分布の条件付き p.d.f. は事前分布と尤度関数の積の定数倍である.

$$\pi_{\Theta|X}(\theta|x) \propto \text{lik}_n(\theta)\pi(\theta).$$

c_n を無視してもよいのだろうか? 必要なときは求めることができるので問題ない. 事後分布の平均やモード (最頻値) を推測に用いることが多い. たとえば,

$$\int \{y - \theta\}^2 \pi_{\Theta|X}(\theta|x) d\theta$$

を最小にする y の値を $\bar{\theta}$ と書くと

$$\bar{\theta} = \frac{\int \theta \pi_{\Theta|X}(\theta|x) d\theta}{\int \theta^2 \pi_{\Theta|X}(\theta|x) d\theta} = \frac{\int \theta \text{lik}_n(\theta)\pi(\theta) d\theta}{\int \theta^2 \text{lik}_n(\theta)\pi(\theta) d\theta}$$

と表現できる. また信頼区間であれば, $0 < \alpha < 1/2$ に対して

$$\int_{-\infty}^a \pi_{\Theta|X}(\theta|x) d\theta = \int_b^{\infty} \pi_{\Theta|X}(\theta|x) d\theta$$

をみたく a, b を求めると開区間 $C = (a, b)$ は

$$\Pr(\theta \in C) = 1 - \alpha$$

をみたく事後信頼区間となる.

例 9.1. $X_1, X_2, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} \text{Ber}(\theta)$ ($0 < \theta < 1$) とし, 事前分布は $(0, 1)$ 上の一様分布とする. すなわち

$$\pi(\theta) = \begin{cases} 1 & (0 < \theta < 1) \\ 0 & (\text{その他の場合}) \end{cases}$$

である. すると

$$\begin{aligned} \pi_{\Theta|X}(\theta|x) &\propto \pi(\theta)\text{lik}_n(\theta) = \prod_{j=1}^n \theta^{x_j}(1-\theta)^{1-x_j} \mathbb{1}_{\{0,1\}}(x_j) \\ &= \theta^s(1-\theta)^{n-s} \mathbb{1}_{\{0,1,\dots,n\}}(s) \end{aligned}$$

となる. ただし $s = \sum_{j=1}^n x_j$ である.

一方 $\alpha > 0, \beta > 0$ とし

$$\pi(\theta | \alpha, \beta) = \begin{cases} \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} & (x > 0) \\ 0 & (\text{その他の場合}) \end{cases}$$

とする. ただし $\Gamma(\alpha) = \int_0^\infty x^{\alpha-1} e^{-x} dx$ である. すなわち θ の事前分布は $B(\alpha, \beta)$ である. このとき

$$\pi_{\Theta|X}(\theta | \mathbf{x}) = \frac{\Gamma(n+2)}{\Gamma(s+1)\Gamma(n-s+1)} \theta^{(s+1)-1} (1-\theta)^{(n-s+1)-1} \quad (9.1)$$

となる. したがって

$$\Theta | X = \mathbf{x} \sim B(s+1, n-s+1)$$

がわかる. このとき

$$\bar{\theta} = \int \theta \pi_{\Theta|X}(\theta | \mathbf{x}) d\theta$$

とおくと

$$\bar{\theta} = \frac{s+1}{n+2}$$

を得る. $\hat{\theta} = \frac{s}{n}, \tilde{\theta} = \frac{1}{2}$ とおくと

$$\bar{\theta} = \lambda_n \hat{\theta} + (1-\lambda_n) \tilde{\theta}, \quad \lambda_n = \frac{n}{n+2}$$

と書ける.

信頼係数 0.95 の θ の事後信頼区間 $C = (a, b)$ は

$$\int_a^b \pi_{\Theta|X}(\theta | \mathbf{x}) d\theta = 0.95$$

をみたく a, b を数値計算で求めればよい. □

問 9.1. $X_1, X_2, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} \text{Ber}(\theta)$ ($0 < \theta < 1$) とし,

$$\pi(\theta | \alpha, \beta) = \begin{cases} \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} & (x > 0) \\ 0 & (\text{その他の場合}) \end{cases}$$

とする. このとき, $X_1 = x_1, X_2 = x_2, \dots, X_n = x_n$ が与えられたときの Θ の条件付き p.d.f. が (9.1) で与えられることを示せ.

問 9.2. $X \sim B(\alpha, \beta)$ のとき, $E[X] = \frac{\alpha}{\alpha+\beta}$ となることを示せ.

例 9.2. $X_1, X_2, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(\mu, \sigma^2)$ とする. ただし $\mu \in \mathbb{R}$ で σ^2 は既知とする. 事前分布として

$$\Theta \sim N(a, b^2)$$

を仮定する. ただし $a \in \mathbb{R}, 0 < b < \infty$ である. すると

$$\Theta | \mathbf{X} = \mathbf{x} \sim N(\bar{\theta}, \tau^2), \tag{9.2}$$

$$\bar{\theta} = w\bar{x} + (1-w)a, \quad \bar{x} = \frac{1}{n} \sum_{j=1}^n x_j,$$

$$w = \frac{\frac{1}{\text{se}^2}}{\frac{1}{\text{se}^2} + \frac{1}{b^2}}, \quad \frac{1}{\tau^2} = \frac{1}{\text{se}^2} + \frac{1}{b^2}, \quad \text{se} = \frac{\sigma}{\sqrt{n}}$$

となる. 問 9.3 を参照のこと. ただし, $\mathbf{X} = (X_1, X_2, \dots, X_n), \mathbf{x} = (x_1, x_2, \dots, x_n)$ とした.

このように事前分布と事後分布が同じ母数モデルに属するとき, 事前分布はこのモデルに随伴する (conjugate) という. または, このような事前分布を随伴事前分布という.

$n \rightarrow \infty$ のとき $w \rightarrow 1$ かつ $\frac{\tau}{\text{se}} \rightarrow 1$ となる. 標本数が大きいとき

$$\Theta | \mathbf{X} = \mathbf{x} \approx N(\hat{\theta}, \text{se}^2)$$

となる. また n を固定する. $b \rightarrow \infty$ としたとき

$$\Theta | \mathbf{X} = \mathbf{x} \approx N(\hat{\theta}, \text{se}^2)$$

となる. これは一様な事前分布に対応するものである.

区間 $C = (c, d)$ は

$$\Pr(\theta \in C | \mathbf{X} = \mathbf{x}) = 0.95$$

をみたすものとする. したがって

$$\Pr(\theta < c | \mathbf{X} = \mathbf{x}) = 0.025, \quad \Pr(\theta > d | \mathbf{X} = \mathbf{x}) = 0.025$$

となるように c, d を選べばよい. このことから c を以下をみたすように選べばよい.

$$\Pr(\theta < c | \mathbf{X} = \mathbf{x}) = \Pr\left(\frac{\theta - \bar{\theta}}{\tau} < \frac{c - \bar{\theta}}{\tau} \mid \mathbf{X} = \mathbf{x}\right) = \Pr\left(Z < \frac{c - \bar{\theta}}{\tau}\right).$$

ただし $Z \sim N(0, 1)$ である. さらに

$$\Pr(Z < -1.96) = 0.025$$

なので

$$\frac{c - \bar{\theta}}{\tau} = -1.96$$

とすればよい. よって

$$c = \bar{\theta} - 1.96\tau$$

とする. 同様に

$$d = \bar{\theta} + 1.96\tau$$

を得る. これらのことから信頼係数 0.95 の Bayes 的信頼区間は $(\bar{\theta} - 1.96\tau, \bar{\theta} + 1.96\tau)$ となる. さらに $\hat{\theta} \approx \bar{\theta}$ かつ $\tau \approx \text{se}$ なので信頼係数 0.95 の Bayes 的信頼区間は近似的に $(\hat{\theta} - 1.96\text{se}, \hat{\theta} + 1.96\text{se})$ となり, 頻度論的信頼区間と同じになる.

問 9.3. $X_1, X_2, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(\mu, \sigma^2)$ とする. ただし $\mu \in \mathbb{R}$ で σ^2 は既知とする. さらに, 事前分布として

$$\Theta \sim N(a, b^2)$$

を仮定する. ただし $a \in \mathbb{R}, 0 < b < \infty$ である. このとき, $\mathbf{X} = \mathbf{x}$ が与えられたときの Θ の条件付き分布が (9.2) で与えられることを確かめよ.

9.3 事前分布の選択について

9.4 章末注釈と参考文献

この章は [26, pp.175 – 192] を借用した.

9.5 演習問題

演習問題 9.1.

演習問題 9.2.