

Seminar 7: Байесовские методы

Carlos Buitrago

Table of contents

1	Байесовский подход: постановка задачи	1
1.1	Формула Байеса	2
1.2	Байесовская оценка и функция потерь	2
2	Сопряжённые семейства	3
2.1	Основные пары «модель — априорное распределение»	3
2.2	Beta–Binomial	3
2.3	Gamma–Poisson	4
2.4	Gamma–Exponential: параметр интенсивности	4
2.5	Нормальная модель с известной дисперсией	4
2.6	Равномерная модель и распределение Парето	4
3	Априорное распределение Джеффриса	5
3.1	Пример: Poisson	5
3.2	Пример: $N(\mu, 1)$	6
4	Состоятельность: как проверять	6
5	Дискретные априорные распределения и сдвиг равномерного закона	6
5.1	Двухточечный prior для нормального среднего	6
5.2	Пуассоновский prior для $U(\theta, \theta + 1)$	7
6	Численные иллюстрации	7
7	Памятка: алгоритм решения задачи	8

1 Байесовский подход: постановка задачи

В частотном подходе неизвестный параметр θ фиксирован. В байесовском подходе параметр рассматривается как случайная величина Θ с **априорным распределением** π , а данные $X = (X_1, \dots, X_n)$ имеют условное распределение P_θ при $\Theta = \theta$.

i Обозначения

- $\pi(\theta)$ (или $q(\theta)$) — априорная плотность / масса;
- $L(\theta; x) = f(x | \theta)$ — функция правдоподобия;
- $\pi(\theta | x)$ — апостериорная плотность / масса;
- $\delta(X)$ — статистическое решающее правило (оценка).

Для дискретных параметров интегралы заменяются суммами. Не следует путать априорное распределение параметра и распределение наблюдений.

1.1 Формула Байеса

! Определение 1. Априорное распределение

Распределение π параметра Θ до наблюдения данных называется **априорным**.

! Определение 2. Апостериорное распределение

Если $m(x) = \int_{\Theta} L(t; x) \pi(t) dt$ конечно и положительно, то

$$\pi(\theta | x) = \frac{L(\theta; x) \pi(\theta)}{\int_{\Theta} L(t; x) \pi(t) dt}.$$

Знаменатель $m(x)$ называется **маргинальной плотностью данных** (evidence). В вычислениях удобно писать $\pi(\theta | x) \propto L(\theta; x) \pi(\theta)$ и затем нормировать.

Для дискретного параметра:

$$P(\Theta = t | X = x) = \frac{P(X = x | \Theta = t) P(\Theta = t)}{\sum_s P(X = x | \Theta = s) P(\Theta = s)}.$$

1.2 Байесовская оценка и функция потерь

! Определение 3. Байесовская оценка при квадратичной потере

При потере $\ell(a, \theta) = (a - \theta)^2$ байесовская оценка равна

$$\hat{\theta}_B(X) = \mathbb{E}[\Theta | X].$$

Для существования требуется конечный соответствующий апостериорный второй момент (либо достаточно условий, обеспечивающих конечный риск).

i Определение 4. Байесовский риск и оптимальность

Для произвольной потери $\ell(a, \theta)$ частотный риск правила δ :

$$R(\theta, \delta) = \mathbb{E}_{\theta}[\ell(\delta(X), \theta)].$$

Байесовский риск:

$$r(\pi, \delta) = \int_{\Theta} R(\theta, \delta) \pi(d\theta).$$

Правило δ^* **байесовски оптимально**, если $r(\pi, \delta^*) \leq r(\pi, \delta)$ для любого допустимого δ . Строгое неравенство для каждого другого правила, как в исходном конспекте, вообще говоря, не требуется: оптимальных правил может быть несколько.

💡 Теорема. Оптимальность апостериорного среднего

При квадратичной потере и конечных вторых моментах оптимальное правило:

$$\delta^*(X) = \mathbb{E}[\Theta | X].$$

Доказательство. Для фиксированного x и $m(x) = \mathbb{E}[\Theta | X = x]$:

$$\mathbb{E}[(a - \Theta)^2 | X = x] = (a - m(x))^2 + \text{Var}(\Theta | X = x).$$

Минимум достигается при $a = m(x)$. Интегрирование по X даёт минимум байесовского риска. $\square$

⚠ Зависимость от функции потерь

- Квадратичная потеря: апостериорное **среднее**.
- Абсолютная потеря $|a - \theta|$: апостериорная **медиана**.
- Потеря $\mathbf{1}\{a \neq \theta\}$ для дискретного параметра: апостериорная **мода** (MAP).

Поэтому формула «байесовская оценка = апостериорное среднее» предполагает квадратичную потерю.

2 Сопряжённые семейства

! Определение 5. Сопряжённое семейство

Семейство априорных распределений $\{\pi_\eta : \eta \in H\}$ называется **сопряжённым** к модели $\{P_\theta\}$, если апостериорное распределение принадлежит тому же семейству для всех допустимых выборок (с обновлённым гиперпараметром $\eta' = T(\eta, x)$).

2.1 Основные пары «модель — априорное распределение»

Условная модель	Априорное распределение	Апостериорное распределение
$X_i \sim \text{Bern}(p)$	$p \sim \text{Beta}(\alpha, \beta)$	$\text{Beta}(\alpha + S, \beta + n - S)$
$X_i \sim \text{Bin}(m, p)$	$p \sim \text{Beta}(\alpha, \beta)$	$\text{Beta}(\alpha + S, \beta + nm - S)$
$X_i \sim \text{Pois}(\lambda)$	$\lambda \sim \text{Gamma}(\alpha, \beta)$	$\text{Gamma}(\alpha + S, \beta + n)$
$X_i \sim \text{Exp}(\lambda)$, интенсивность λ	$\lambda \sim \text{Gamma}(\alpha, \beta)$	$\text{Gamma}(\alpha + n, \beta + S)$
$X_i \sim N(\mu, \sigma^2)$, σ^2 известно	$\mu \sim N(a, \tau^2)$	$N(m_n, v_n)$
$X_i \sim N(0, v)$, v неизвестна	$v \sim \text{InvGamma}(\alpha, \beta)$	$\text{InvGamma}(\alpha + n/2, \beta + \sum X_i^2/2)$
$X_i \sim U(0, \theta)$	$\theta \sim \text{Pareto}(b, \alpha)$	$\text{Pareto}(\max(b, M), \alpha + n)$

Здесь $S = \sum_i X_i$, $M = \max_i X_i$; Gamma использует параметризацию **shape–rate**:

$$f(\lambda) = \frac{\beta^\alpha}{\Gamma(\alpha)} \lambda^{\alpha-1} e^{-\beta\lambda}, \quad \mathbb{E}\lambda = \frac{\alpha}{\beta}.$$

Для $\text{InvGamma}(\alpha, \beta)$ плотность $\propto v^{-\alpha-1} e^{-\beta/v}$ и среднее $\beta/(\alpha - 1)$ при $\alpha > 1$.

2.2 Beta–Binomial

Пусть $X_i \sim \text{Bin}(m, p)$, $p \sim \text{Beta}(\alpha, \beta)$, $S = \sum_i X_i$. Тогда

$$L(p; x) \propto p^S (1 - p)^{nm - S}, \quad \pi(p) \propto p^{\alpha-1} (1 - p)^{\beta-1},$$

$$p | X \sim \text{Beta}(\alpha + S, \beta + nm - S), \quad \hat{p}_B = \frac{\alpha + S}{\alpha + \beta + nm}.$$

Если α, β фиксированы, $\hat{p}_B \xrightarrow{P} p_0$ по ЗБЧ при истинном p_0 .

2.3 Gamma–Poisson

Для $X_i \sim \text{Pois}(\lambda)$, $\lambda \sim \text{Gamma}(\alpha, \beta)$:

$$\pi(\lambda | x) \propto \lambda^{\alpha+S-1} e^{-(\beta+n)\lambda},$$

$$\hat{\lambda}_B = \frac{\alpha + S}{\beta + n}.$$

2.4 Gamma–Exponential: параметр интенсивности

Если $f(x | \lambda) = \lambda e^{-\lambda x} \mathbf{1}_{x \geq 0}$, то

$$\lambda | X \sim \text{Gamma}(\alpha + n, \beta + S), \quad \hat{\lambda}_B = \frac{\alpha + n}{\beta + S} \xrightarrow{P} \lambda_0.$$

⚠ Если θ — масштаб, а не интенсивность

При $f(x | \theta) = \theta^{-1} e^{-x/\theta}$, $\theta > 0$, сопряжённое распределение — **обратное гамма-распределение**:

$$\theta \sim \text{InvGamma}(\alpha, \beta) \implies \theta | X \sim \text{InvGamma}(\alpha + n, \beta + S),$$

$$\hat{\theta}_B = \frac{\beta + S}{\alpha + n - 1}, \quad \alpha + n > 1.$$

Параметризацию экспоненциального распределения всегда нужно оговаривать.

2.5 Нормальная модель с известной дисперсией

Если $X_i | \mu \sim N(\mu, \sigma^2)$ и $\mu \sim N(a, \tau^2)$, то

$$v_n = \left(\frac{1}{\tau^2} + \frac{n}{\sigma^2} \right)^{-1}, \quad m_n = v_n \left(\frac{a}{\tau^2} + \frac{n\bar{X}}{\sigma^2} \right),$$

$$\mu | X \sim N(m_n, v_n), \quad \hat{\mu}_B = m_n.$$

💡 Вывод дополнением до квадрата

Логарифм апостериорной плотности с точностью до константы равен

$$-\frac{(\mu - a)^2}{2\tau^2} - \frac{\sum_i (X_i - \mu)^2}{2\sigma^2} = -\frac{(\mu - m_n)^2}{2v_n} + C(x).$$

При фиксированных a, τ^2, σ^2 коэффициент при $\bar{X}$ стремится к 1, поэтому $m_n \xrightarrow{P} \mu_0$.

2.6 Равномерная модель и распределение Парето

Если $X_i | \theta \sim U(0, \theta)$, то $L(\theta; x) = \theta^{-n} \mathbf{1}_{\theta \geq M}$ (при неотрицательных наблюдениях).

Для априорного $\text{Pareto}(b, \alpha)$ с плотностью

$$\pi(\theta) = \alpha b^\alpha \theta^{-\alpha-1} \mathbf{1}_{\theta \geq b},$$

получаем $\theta \mid X \sim \text{Pareto}(c, \alpha + n)$, $c = \max(b, M)$, и

$$\hat{\theta}_B = \frac{\alpha + n}{\alpha + n - 1} c \quad (\alpha + n > 1).$$

Если истинное $\theta_0 \geq b$, то $M \rightarrow \theta_0$ почти наверное, значит оценка состоятельна.

i Другой равномерный случай: априорное $U(0, 1)$

При $0 \leq M < 1$ апостериорная плотность пропорциональна $\theta^{-n} \mathbf{1}_{[M, 1]}(\theta)$. Для $0 < M < 1$:

$$\hat{\theta}_B = \frac{\int_M^1 t^{1-n} dt}{\int_M^1 t^{-n} dt}.$$

Для $n \geq 3$:

$$\hat{\theta}_B = \frac{n-1}{n-2} \frac{M^{2-n} - 1}{M^{1-n} - 1}.$$

При $n = 2$: $\hat{\theta}_B = \frac{\log(1/M)}{M^{-1}-1}$; при $n = 1$: $\hat{\theta}_B = \frac{1-M}{\log(1/M)}$. Если $M \rightarrow \theta_0 \in (0, 1)$, то апостериорная оценка всё равно стремится к θ_0 при $n \rightarrow \infty$.

3 Априорное распределение Джеффриса

! Определение 6. Правило Джеффриса

Для одномерной регулярной модели с информацией Фишера от **одного наблюдения**

$$I(\theta) = \mathbb{E}_\theta \left[\left(\frac{\partial}{\partial \theta} \log f(X \mid \theta) \right)^2 \right],$$

априорная плотность Джеффриса задаётся (с точностью до множителя)

$$\pi_J(\theta) \propto \sqrt{I(\theta)}.$$

Для векторного параметра $\pi_J(\theta) \propto \sqrt{\det I(\theta)}$.

! Важные оговорки

Априорное распределение Джеффриса может быть **несобственным** (не интегрироваться в единицу). Использовать его можно, если полученное апостериорное распределение собственное. Формулы регулярной информации требуют условий дифференцируемости и интегрируемости; для модели $U(0, \theta)$ с зависящим от параметра носителем стандартные регулярные тождества могут не выполняться.

3.1 Пример: Poisson

$$\log f(x \mid \lambda) = -\lambda + x \log \lambda - \log(x!), \quad I(\lambda) = \frac{1}{\lambda}.$$

Следовательно, $\pi_J(\lambda) \propto \lambda^{-1/2}$, то есть формально $\text{Gamma}(1/2, 0)$ (несобственное предельное обозначение).

После $n \geq 1$ наблюдений:

$$\lambda \mid X \sim \text{Gamma}(S + 1/2, n), \quad \hat{\lambda}_J = \frac{S + 1/2}{n} = \bar{X} + \frac{1}{2n}.$$

3.2 Пример: $N(\mu, 1)$

$I(\mu) = 1$, значит $\pi_J(\mu) \propto 1$ на $\mathbb{R}$ (несобственное равномерное распределение). При $n \geq 1$:

$$\mu \mid X \sim N(\bar{X}, 1/n), \quad \hat{\mu}_J = \bar{X}.$$

💡 Сравнение с сопряжёнными априорными распределениями

Для Poisson с $\text{Gamma}(\alpha, \beta)$ получаем $(S + \alpha)/(n + \beta)$; при Джеффрисе — $(S + 1/2)/n$. Для нормальной модели с априорным $N(a, \tau^2)$ получаем взвешенное среднее, а при Джеффрисе — $\bar{X}$.

4 Состоятельность: как проверять

❗ Определение

Оценка $\delta_n(X_1, \dots, X_n)$ **состоятельна** в точке θ_0 , если при выборке из P_{θ_0}

$$\delta_n \xrightarrow[n \rightarrow \infty]{P_{\theta_0}} \theta_0.$$

Состоятельность — **частотное** свойство, даже если правило построено байесовским способом.

Полезные факты: $\bar{X} \xrightarrow{P} \mathbb{E}_{\theta_0} X_1$ по ЗБЧ; для $U(0, \theta_0)$

$$P_{\theta_0}(M_n \leq t) = (t/\theta_0)^n, \quad 0 \leq t \leq \theta_0, \quad M_n \xrightarrow{a.s.} \theta_0.$$

Для $U(\theta_0, \theta_0 + 1)$ минимум $m_n \rightarrow \theta_0$, максимум $M_n \rightarrow \theta_0 + 1$ почти наверное.

⚠ Ограничение носителя априорного распределения

Если истинное значение параметра исключено априорным распределением, байесовская оценка может быть несостоятельной. В частности, при априорном $\text{Bern}(p)$ параметр может принимать **только 0 или 1**, поэтому состоятельность следует проверять только для $\theta_0 \in \{0, 1\}$ в рамках байесовской модели.

5 Дискретные априорные распределения и сдвиг равномерного закона

5.1 Двухточечный приор для нормального среднего

Пусть $X_i \mid \theta \sim N(\theta, 1)$ и $P(\Theta = 1) = p$, $P(\Theta = 0) = 1 - p$, $0 < p < 1$. Тогда

$$\frac{P(\Theta = 1 \mid x)}{P(\Theta = 0 \mid x)} = \frac{p}{1 - p} \exp\left(S - \frac{n}{2}\right),$$

$$\hat{\theta}_B = P(\Theta = 1 \mid X) = \frac{pe^{S-n/2}}{1 - p + pe^{S-n/2}}.$$

При $\theta_0 = 1$ логарифм апостериорных шансов $= \log(p/(1-p)) + n/2 + O_P(\sqrt{n}) \rightarrow +\infty$, а при $\theta_0 = 0$ он стремится к $-\infty$. Значит оценка состоятельна на $\{0, 1\}$. При $p = 0$ или 1 prior вырожден и вывод меняется.

5.2 Пуассоновский prior для $U(\theta, \theta + 1)$

Пусть $\Theta \sim \text{Pois}(1)$, так что $\Theta = k \in \{0, 1, 2, \dots\}$ с весами $e^{-1}/k!$. Для наблюдений x правдоподобие при k равно

$$L(k; x) = \mathbf{1}\{k \leq m, M \leq k + 1\}, \quad m = \min_i x_i, \quad M = \max_i x_i.$$

Следовательно,


$$P(\Theta = k | x) = \frac{\frac{1}{k!} \mathbf{1}\{M - 1 \leq k \leq m\}}{\sum_{j \geq 0} \frac{1}{j!} \mathbf{1}\{M - 1 \leq j \leq m\}},$$


$$\hat{\theta}_B = \frac{\sum_{k \geq 0} \frac{k}{k!} \mathbf{1}\{M - 1 \leq k \leq m\}}{\sum_{k \geq 0} \frac{1}{k!} \mathbf{1}\{M - 1 \leq k \leq m\}}.$$

Интервал $[M - 1, m]$ имеет длину $1 - (M - m)$, которая стремится к нулю. При истинном целом $\theta_0 \geq 0$ апостериорное распределение концентрируется в θ_0 и оценка состоятельна. Для нецелого истинного параметра модель priora неверно специфицирована, и универсальная состоятельность не гарантируется.

6 Численные иллюстрации

В следующих экспериментах сравним байесовскую оценку и оценку максимального правдоподобия. Численный эксперимент иллюстрирует, но не заменяет доказательство состоятельности.





7 Памятка: алгоритм решения задачи

1. Уточнить параметризацию распределения и пространство параметров.
2. Выписать правдоподобие $L(\theta; x)$, не забывая индикаторы носителя.
3. Умножить на априорную плотность и определить нормирующую константу.
4. Распознать семейство апостериорного распределения или вычислить интегралы / суммы.
5. Найти апостериорное среднее для квадратичной потери и проверить его существование.
6. Проверить состоятельность при фиксированном истинном θ_0 с учётом носителя приора.
7. Для приора Джеффриса сначала найти информацию Фишера и проверить собственность апостериорного распределения.