


Ch.3 Bayes推論による学習と予測.

§3.1 学習と予測.

* 学習



• データを表現するモデル: $p(D, \theta) = \underbrace{p(D|\theta)}_{\text{尤度}} p(\theta)$.

• $p(D|\theta) = \prod_{n=1}^N p(x_n|\theta)$. (データは i.i.d.)

• データ D を観測した後の $p(\theta|D)$ の更新 (学習):

$$p(\theta|D) = \frac{p(D|\theta)p(\theta)}{p(D)}. \quad (": Bayes' Th.)$$


↑
D についての特徴と定数ははずす.

• **予測分布**: データ D を観測したうえでの新規データ x_* の分布:

$$p(x_*|D) = \mathbb{E}_{p(\theta|D)} [p(x_*|\theta)]$$

$$= \int p(x_*|\theta)p(\theta|D) d\theta.$$

graphical model.



$$p(\mathcal{D}, x_*, \theta) = p(\mathcal{D} | \theta) p(x_* | \theta) p(\theta). \quad (\text{データは i.i.d.})$$

\mathcal{D} : given のとき.

$$p(x_*, \theta | \mathcal{D}) = \frac{p(\mathcal{D}, x_*, \theta)}{p(\mathcal{D})}$$

$$= \frac{p(\mathcal{D} | \theta) p(x_* | \theta) p(\theta)}{p(\mathcal{D})} = p(\theta | \mathcal{D})$$

$$= p(x_* | \theta) p(\theta | \mathcal{D}).$$

↓ θ を積分除去

$$p(x_* | \mathcal{D}). \quad \text{予測分布}$$

・ データ \mathcal{D} の情報をすべて事後分布 $p(\theta | \mathcal{D})$ に押し込められる.

→ 計算が便利.

・ データ量に対して, モデルの表現能力は変化しない.

cf) Gauss 過程 などの Bayesian ノンパラメトリクス.

* 共役事前分布

事前分布 $p(\theta)$ と事後分布 $p(\theta|D)$ が同じ種類の確率分布とものように設定された事前分布.

- 尤度 $p(D|\theta)$ のかたちに依存.
- 学習させるパラメータにも依存.

✓ 事後分布 $p(\theta|D)$ や予測分布 $p(x_*|D)$ の計算が楽!

- 共役でない事前分布とつかう.

→ 事後分布 $p(\theta|D)$ は事前分布 $p(\theta)$ と違う種類の分布になる.

→ MCMC, 変分推論の利用.

◦ 変分推論

$p(\theta|D) \approx q(\theta; \eta)$ と仮定.
↳ 変分パラメータ

η の最適化:

$$\eta_{\text{opt}} := \underset{\eta}{\operatorname{argmin}} \operatorname{KL}[q(\theta; \eta) \| p(\theta|D)].$$

ふたつ, これは解析的に解けない. → 勾配法.

§3.2 離散確率分布の学習と予測.

* Bernoulli分布.

$$p(x|\mu) = \text{Bern}(x|\mu). \quad \mu \text{ の分布を推論}$$

$\mu \in (0, 1)$ を生成する分布? \rightarrow \wedge -分布.

$$p(\mu) = \text{Beta}(\mu|a, b), \quad a, b: 1 \leq a, b < \infty$$

Bernoulli分布からの N 個のデータ $\mathcal{X} = \{x_1, \dots, x_N\}$: given

$$p(\mu|\mathcal{X}) = \frac{p(\mathcal{X}|\mu)p(\mu)}{p(\mathcal{X})} \quad (\because \text{Bayes' Th.})$$

$$\propto p(\mathcal{X}|\mu)p(\mu) \quad (p(\mathcal{X}) = \text{const.})$$

$$= \prod_{i=1}^N p(x_i|\mu)p(\mu)$$

μ の分布に興味があるから、
 μ が関係するところだけ見れば十分!

$$\log p(\mu|\mathcal{X}) = \sum_{i=1}^N \log p(x_i|\mu) + \log p(\mu) + \text{const.}$$

$$\log \text{Beta}(\mu|\hat{a}, \hat{b}) \text{ の形を求めている} = \sum_{i=1}^N x_i \log \mu + \sum_{i=1}^N (1-x_i) \log(1-\mu) + (a-1) \log \mu + (b-1) \log(1-\mu) + \text{const.}$$

$$= \left(\sum_{i=1}^N x_i + a - 1 \right) \log \mu + \left(N - \sum_{i=1}^N x_i + b - 1 \right) \log(1-\mu) + \text{const.}$$

$\sum_{i=1}^N x_i + a - 1$ $\Rightarrow \hat{a}$
 $x_i = 1$ とする回数

$\sum_{i=1}^N (1-x_i) + b - 1$ $\Rightarrow \hat{b}$
 $x_i = 0$ とする回数

$$\therefore p(\mu|\mathcal{X}) = \text{Beta}(\mu|\hat{a}, \hat{b}).$$

μ のデータを観測した後の分布も事前分布と同じ \wedge -分布なので、
 事後事前分布であることが分かる。

- 未観測値 $x_* \in \{0, 1\}$ の予測分布.

$$\begin{aligned}
 p(x_*) &= \int p(x_* | \mu) p(\mu) d\mu \\
 &= \int \text{Bern}(x_* | \mu) \text{Beta}(\mu | a, b) d\mu \\
 &= C_B(a, b) \int \mu^{x_*} (1-\mu)^{1-x_*} \mu^{a-1} (1-\mu)^{b-1} d\mu \\
 &= C_B(a, b) \frac{1}{C_B(x_*+a, 1-x_*+b)} \\
 &= \frac{\Gamma(a+b) \Gamma(x_*+a) \Gamma(1-x_*+b)}{\Gamma(a) \Gamma(b) \Gamma(a+b+1)} \\
 &= \frac{1}{a+b} \frac{\Gamma(x_*+a) \Gamma(1-x_*+b)}{\Gamma(a) \Gamma(b)}.
 \end{aligned}$$

$x_* \in \{0, 1\}$ に対する場合分け.

$$p(x_* = 1) = \frac{1}{a+b} \frac{\Gamma(1+a) \cancel{\Gamma(b)}}{\Gamma(a) \cancel{\Gamma(b)}} = \frac{1}{a+b} \frac{a \cancel{\Gamma(a)}}{\cancel{\Gamma(a)}} = \frac{a}{a+b}$$

$$p(x_* = 0) = \frac{1}{a+b} \frac{\cancel{\Gamma(a)} \Gamma(1+b)}{\cancel{\Gamma(a)} \Gamma(b)} = \frac{1}{a+b} \frac{b \cancel{\Gamma(b)}}{\cancel{\Gamma(b)}} = \frac{b}{a+b}$$

$$\therefore p(x_*) = \left(\frac{a}{a+b}\right)^{x_*} \left(\frac{b}{a+b}\right)^{1-x_*} = \text{Bern}\left(x_* \mid \frac{a}{a+b}\right).$$

→ データが... あるときも同様に

$$p(x_* | \mathcal{D}) = \text{Bern}\left(x_* \mid \frac{\hat{a}}{\hat{a} + \hat{b}}\right).$$

* カテゴリ分布. (K 値)

$$p(s|\pi) = \text{Cat}(s|\pi), \quad \frac{\sum_{k=1}^K \pi_k = 1, \pi_k \in (0,1)}{-(*)}$$

(*) とみたとき π を生成する分布? \rightarrow Dirichlet分布.

$$p(\pi) = \text{Dir}(\pi|\alpha) = C_D(\alpha) \prod_{k=1}^K \pi_k^{\alpha_k-1}.$$

カテゴリ分布からの N 個のデータ $\mathcal{S} = \{s_1, \dots, s_N\}$: given.

$$p(\pi|\mathcal{S}) \propto p(\mathcal{S}|\pi)p(\pi).$$

$$= \prod_{i=1}^N \text{Cat}(s_i|\pi) \text{Dir}(\pi|\alpha).$$

$$\log p(\pi|\mathcal{S}) = \sum_{i=1}^N \log \text{Cat}(s_i|\pi) + \log \text{Dir}(\pi|\alpha) + \text{const.}$$

$$= \sum_{i=1}^N \sum_{k=1}^K s_{i,k} \log \pi_k + \sum_{k=1}^K (\alpha_k - 1) \log \pi_k + \underbrace{\log C_D(\alpha)}_{\text{const.}} + \text{const.}$$

$$= \sum_{k=1}^K \left(\underbrace{\sum_{i=1}^N s_{i,k} + \alpha_k - 1}_{=: \hat{\alpha}_k} \right) \log \pi_k + \text{const.}$$

$$=: \hat{\alpha}_k$$

事後分布も Dirichlet分布になる.

$$\therefore p(\pi|\mathcal{S}) = \text{Dir}(\pi|\hat{\alpha}).$$

未観測データ s_* の予測分布.

$$p(s_*) = \int p(s_*|\pi) p(\pi) d\pi.$$

$$= \int \text{Cat}(s_*|\pi) \text{Dir}(\pi|\alpha) d\pi$$

$$= C_D(\alpha) \int \prod_{k=1}^K \pi_k^{S_{*,k}} \cdot \pi_k^{\alpha_k - 1} d\pi$$

$$= C_D(\alpha) \int \prod_{k=1}^K \pi_k^{S_{*,k} + \alpha_k - 1} d\pi$$

$$= \frac{C_D(\alpha)}{C_D((S_{*,k} + \alpha_k)_{k=1}^K)}$$

$$= \frac{\Gamma\left(\sum_{k=1}^K \alpha_k\right) \prod_{k=1}^K \Gamma(S_{*,k} + \alpha_k)}{\left(\prod_{k=1}^K \Gamma(\alpha_k)\right) \Gamma\left(\sum_{k=1}^K (S_{*,k} + \alpha_k)\right)}$$

$$P(S_{*,k'} = 1) = \frac{\Gamma\left(\sum_{k=1}^K \alpha_k\right) \alpha_{k'} \prod_{k=1}^K \Gamma(\alpha_k)}{\left(\prod_{k=1}^K \Gamma(\alpha_k)\right) \left(\sum_{k=1}^K \alpha_k\right) \Gamma\left(\sum_{k=1}^K \alpha_k\right)} = \frac{\alpha_{k'}}{\sum_{k=1}^K \alpha_k}$$

$S_{*,k'} = 1$ のとき

$k \neq k' = 2$ のとき

$S_{*,k} = 0$ に注意.

Γ はガンマ関数の性質 $\Gamma(x+1) = x\Gamma(x)$ を用いる.

$$\therefore P(S_*) = \text{Cat}\left(S_* \mid \left(\frac{\alpha_k}{\sum_{k=1}^K \alpha_k}\right)_{k=1}^K\right)$$

データ \mathcal{D} があるときも同様に,

$$P(S_* | \mathcal{D}) = \text{Cat}\left(S_* \mid \left(\frac{\hat{\alpha}_k}{\sum_{k=1}^K \hat{\alpha}_k}\right)_{k=1}^K\right)$$

* Poisson 分布.

$$p(x|\lambda) = \text{Poi}(x|\lambda), \quad \lambda \in \mathbb{R}_{>0}.$$

$\lambda \in \mathbb{R}_{>0}$ を生成する dist. ? \rightarrow ガンマ分布.

$$p(\lambda) = \text{Gam}(\lambda|a, b).$$

• Poisson 分布 x_i の N 個の \mathcal{T} -th $\mathcal{X} = \{x_1, \dots, x_N\}$.

$$p(\lambda|\mathcal{X}) \propto p(\mathcal{X}|\lambda) p(\lambda)$$

$$= \prod_{i=1}^N \text{Poi}(x_i|\lambda) \text{Gam}(\lambda|a, b)$$

$$\log p(\lambda|\mathcal{X}) = \sum_{i=1}^N \log \text{Poi}(x_i|\lambda) + \log \text{Gam}(\lambda|a, b) + \text{const.}$$

$$= \sum_{i=1}^N (x_i \log \lambda - \underbrace{\log x_i!}_{\text{const.}} - \lambda) + (a-1) \log \lambda - b\lambda + \underbrace{\log C_G(a, b)}_{\text{const.}} + \text{const.}$$

$$= \left(\underbrace{\sum_{i=1}^N x_i + a - 1}_{=: \hat{a}} \right) \log \lambda - \underbrace{(N+b)}_{=: \hat{b}} \lambda + \text{const.}$$

$$\therefore p(\lambda|\mathcal{X}) = \text{Gam}(\lambda|\hat{a}, \hat{b}).$$

• x_* の \mathcal{T} -則分布

$$p(x_*) = \int \text{Poi}(x_*|\lambda) \text{Gam}(\lambda|a, b) d\lambda$$

$$= \frac{C_G(a, b)}{x_*!} \int \lambda^{x_*+a-1} e^{-(1+b)\lambda} d\lambda$$

$$= \frac{C_G(a, b)}{x_*! C_G(x_*+a, 1+b)}$$

$$= p \sum_{x=0}^{\infty} x \frac{\Gamma(x+r)}{x! \Gamma(r)} (1-p)^r p^x + pr \sum_{x=0}^{\infty} \frac{\Gamma(x+r)}{x! \Gamma(r)} (1-p)^r p^x$$

$= E[X]$
 $= 1$

$$= p E[X] + pr$$

$$\therefore E[X] = \frac{pr}{1-p}$$

負の二項分布の分散

$$E[X^2] = \sum_{x=0}^{\infty} x^2 \frac{\Gamma(x+r)}{x! \Gamma(r)} (1-p)^r p^x$$

$$= \sum_{x=1}^{\infty} x \frac{\Gamma(x+r)}{(x-1)! \Gamma(r)} (1-p)^r p^x$$

$$= p \sum_{x=1}^{\infty} x \frac{\Gamma(x+r)}{(x-1)! \Gamma(r)} (1-p)^r p^{x-1}$$

$$= p \sum_{x=0}^{\infty} (x+1) \frac{\Gamma(x+r+1)}{x! \Gamma(r)} (1-p)^r p^x$$

$$= p \sum_{x=0}^{\infty} (x+1)(x+r) \frac{\Gamma(x+r)}{x! \Gamma(r)} (1-p)^r p^x$$

$$= p \sum_{x=0}^{\infty} (x^2 + (r+1)x + r) \frac{\Gamma(x+r)}{x! \Gamma(r)} (1-p)^r p^x$$

$$= p E[X^2] + p(r+1) E[X] + pr$$

$$= p E[X^2] + p(r+1) \frac{pr}{1-p} + pr$$

$$\therefore E[X^2] = p(r+1) \frac{pr}{(1-p)^2} + \frac{pr}{1-p} = \frac{pr(pr+1)}{(1-p)^2}$$

$$\therefore V[X] = E[X^2] - (E[X])^2 = \frac{pr}{(1-p)^2}$$

$x-1$ を x に
変える

Γ の性質