

## 2.1.1 ベータ分布

茨城大学工学部情報工学科

05T4072R

相原 功昌

# ベータ分布

- 式2.13で表される

$$Beta(\mu | a, b) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \mu^{a-1} (1-\mu)^{b-1} \quad \dots (2.13)$$

- 正規化されている→式2.14

$$\int_0^1 Beta(\mu | a, b) d\mu = 1 \quad \dots (2.14)$$

# ガンマ関数


- 式1.141で定義される

$$\Gamma(x) \equiv \int_0^{\infty} u^{x-1} e^{-u} du \quad \dots(1.141)$$


# ベータ分布の必要性

- ベルヌーイ分布と二項分布のパラメータ  $\mu$  の最尤推定(式2.8)

→データ集合が小さいと過学習してしまう



ベイズ主義的に扱う



$\mu$  の事前分布  $p(\mu)$  を導入

# 共役性

尤度関数:  $\mu^x (1-\mu)^{1-x}$

事前分布が、 $\mu$ と $(1-\mu)$ のべき乗に比例するよう  
に選択

事後分布は、事前分布と尤度関数の積に比例  
→事後分布は事前分布と同じ関数形式

# ベータ分布の平均と分散

- 平均→式2.15

$$E[\mu] = \frac{a}{a+b} \quad \dots(2.15)$$

- 分散→式2.16

$$\text{var}[\mu] = \frac{ab}{(a+b)^2(a+b+1)} \quad \dots(2.16)$$

# 超パラメータ

- パラメータ $a$ と $b$ はパラメータ $\mu$ の分布を決める  
→超パラメータ(hyperparameter)と呼ばれることがある

# ベータ分布のグラフ

- ベータ分布のグラフを図2.2に示す




図2.2 ベータ分布

# 有効観測数(1)

- $\mu$  の事後分布  
= 事前分布(式2.13)  $\times$  二項尤度関数(式2.9)
- $\mu$  に依存する要素を取り出す  
→ 式2.17

$$p(\mu | m, l, a, b) \propto \mu^{m+a-1} (1-\mu)^{l+b-1} \cdots (2.17)$$

- $l=N-m$  はコイン投げの例の「裏」の数に相当

## 有効観測数(2)

- 式2.17をベータ分布として完結に表す  
→式2.18

$$p(\mu | m, l, a, b) = \frac{\Gamma(m + a + l + b)}{\Gamma(m + a)\Gamma(l + b)} \mu^{m+a-1} (1 - \mu)^{l+b-1} \dots(2.18)$$

- $x=1$ となる観測値を  $m$  個  
 $x=0$ となる観測値を 1 個 となるデータ集合を考える

## 有効観測数(3)

- 事前分布から、この集合を観測した後の事後分布を求める  
→ $a$ の値を $m$ 、 $b$ の値を1だけ増やせばいい
- 超パラメータ $a$ と $b$   
→ $x=1$ と $x=0$ の**有効観測数**として解釈

# 逐次学習(1)

- (1) 事前分布を得る
- (2) 値を観測する
- (3) 事後分布を得る
- (4) (3)で得た事後分布を事前分布とみなして、(2)～(4)を繰り返す

## 逐次学習(2)

- データが独立同分布に従えば成り立つ
- 全てのデータが届く前に予測をしなければならぬ実時間での学習などに利用
- 大規模データ集合についても有用

## 正確な予測(1)

- できるだけ正確に、次の試行の出力を予測する  
→観測データ集合 $D$ が与えられた時の $x$ の予測分布を考える →式2.19

$$\begin{aligned} p(x=1 | D) &= \int_0^1 p(x=1 | \mu) p(\mu | D) d\mu \\ &= \int_0^1 \mu p(\mu | D) d\mu \\ &= E[\mu | D] \end{aligned} \quad \dots(2.19)$$

## 正確な予測(2)

- 式2.18と式2.15から、式2.20を得る

$$p(x = 1 | D) = \frac{m + a}{m + a + l + b} \quad \dots (2.20)$$

- 観測値の、 $x = 1$ に相当するものの、総数に対する割合
- $m, l \rightarrow \infty$ の極限では、式2.20の結果は最尤推定の結果と等しくなる

# ベイズ学習の特性

- 多くのデータを観測するほど、事後分布が示す不確実性は恒常的に減少する  
→ 図2.2から、観測値の数が増えるに従って、事後分布のピークが鋭くなる