


# ベイジアンになろう



電子情報工学科  
伊庭 斉志



# 確率の復習



## 条件付き確率


Aが起こったという条件でBが起きるとい  
事象を  $B|A$  であらわす

その確率  $P(B|A)$  を条件AのもとでのBの  
起きる**条件付き確率**といい、

$$P(B|A) = \frac{P(A \cap B)}{P(A)}$$

で定義する

# 確率の復習




## 周辺確率

Aが起こったとときに同時に $B_1, B_2, \dots, B_m$ のいずれかが起きるとする。ただし $B_1, B_2, \dots, B_m$ は同時には起こらない。このとき、Aがおこる確率は以下のように表わされる。

$$P(A) = \sum_{i=1}^m P(A, B_i) = \sum_{i=1}^m P(A | B_i) P(B_i)$$

# 確率の復習



## 乗法定理


$$P(B | A) = \frac{P(A \cap B)}{P(A)} \quad P(A | B) = \frac{P(A \cap B)}{P(B)}$$

から

$$P(A \cap B) = P(A)P(B | A) = P(B)P(A | B)$$

が得られる

# 例題



- あなたは乳ガンの検査(マンモグラフィ)で陽性になった。
  - この検査では、乳ガンになっている人を見つける正確さは90%、なっていない人を見つける正確さは93%である。
  - あなたが本当にガンである確率はいくつか？
  - ただし、病気の発生確率は0.8%である。
- 
- 検査は90%近く正確なのだから、非常に可能性がある？？ (たいていの医者はこちら答えた)
- 
- 本当か？

# ベイズの定理

- **用途**  
結果が起きたとき、その原因を調べる
- **結果の確率 (事前確率)**
- **原因の確率 (事後確率)**



- **原因**  $A_1, A_2, \dots, A_n$  (n個の排反)
- **結果**  $E$



# ベイズの定理


結果  $E$  が起ったときに原因が  $A_i$  である確率は

$$P(A_i | E) = \frac{P(A_i)P(E | A_i)}{P(A_1)P(E | A_1) + P(A_2)P(E | A_2) + \cdots + P(A_n)P(E | A_n)}$$



Thomas Bayes  
1702 – 1761

# ベイズの定理: 例題




- 同一の製品をつくっている3個の機械A,B,Cがある。
- A,B,Cは全製品のそれぞれ30%, 25%, 45%を生産する。
- A,B,Cの製品中の不良品の割合は,それぞれ1%, 1.2%, 2%であるとする。
- いま,全製品中から1個の製品をとりだしたとき,それが不良品であったという。
- この製品がA,B,Cのそれぞれの機械から生産された確率を求めよ.

# Monty Hall問題



## 3囚人の問題



- 3人の囚人A、B、Cがいる。三人とも処刑されることになっていたが、一人だけ恩赦されることになった。誰が恩赦になるのか決定されたが、まだ囚人たちには知らされていない。
- 結果を知っている看守に、囚人Aが『BとCのうち、どちらかは必ず処刑されるのだから、処刑される一人の名前を教えてください。私に情報を与えることにはならないだろう。一人を教えてくださいませんか。』と頼んだ。
- 看守は、その言い分に納得して『囚人Bは処刑されるよ』と教えてやった。
- 囚人Aは、「はじめ自分の助かる確率は1/3だった。いまや助かるのは自分とCだけになったので、助かる確率は1/2になった」と喜んだ。

# ベイズの定理

結果  $E$  が起ったときに原因が  $A_i$  である確率は

$$P(A_i | E) = \frac{P(A_i)P(E | A_i)}{P(A_1)P(E | A_1) + P(A_2)P(E | A_2) + \cdots + P(A_n)P(E | A_n)}$$



Thomas Bayes  
1702 – 1761


# ベイズの定理

データ $X$ のモデルに基づく  
生成率

モデル $\Theta$ の事前確率

$$p(\Theta|X) = \frac{p(X|\Theta)p(\Theta)}{p(X)} = \frac{p(X|\Theta)p(\Theta)}{\sum_{\Theta'} p(X|\Theta')p(\Theta')}$$

モデル $\Theta$ の事後確率  
(データ $X$ を観測した後)





# 最尤推定 (ML: Most likelihood)

---

$$\hat{\theta} = \arg \max_{\theta} p(y_o | \theta)$$

- 観測データの確率を最大にするようにパラメータを最適化する
- $y_o$  : 観測データ
- $p(y / \theta)$  : モデル
- $\theta$  : モデルのパラメータ

# 最尤推定 (ML: Most likelihood)

$$\hat{\theta} = \arg \max_{\theta} p(y_o|\theta)$$

- 例: コインが1つある。このコインを5回投げたところ、表、表、裏、表、裏と出た。このコインの表の出る確率を $\theta$ とし、この値を推定せよ。





# 最尤推定 (ML: Most likelihood)

---

- $P(D|\theta)$  (尤度)

- モデルパラメータ  $\theta$  のもとでのデータ  $D$  の出現確率

- 最尤法

- $P(D|\theta)$  を最大化する  $\theta$  を選ぶ

- 例

- コインを5回投げて、表が3回出た後、裏が2回出た
- $p(\text{表})=a, p(\text{裏})=1-a$  とすると、 $P(D|\theta)=a^3(1-a)^2$
- $a=3/5$  の時、 $P(D|\theta)$  は最大
- 一般に表が出る頻度を  $f$  とすると  $a=f$  で尤度は最大

# MAP推定 (Maximum *A-Posteriori* Estimation)

$$\hat{\theta} = \arg \max_{\theta} p(\theta|y_o) \quad \text{式(1)}$$


$$\hat{\theta} = \arg \max_{\theta} p(y_o|\theta) p(\theta) \quad \text{式(2)}$$

- 観測データが与えられたときのパラメータの事後確率を最大にするパラメータを求める
- ベイズの定理から分母を無視すると、(2)が導かれる
- $p(\theta)$  : 事前確率

$$\Pr[\theta|X] = \frac{\Pr[X|\theta] \Pr[\theta]}{\int \Pr[X|\theta] \Pr[\theta] d\theta}$$

# ベイズ推定


- パラメータ $\theta$  を確率変数とみなして、パラメータの値の確信度を確率密度分布を用いて表現する。



- データを観測する前にパラメータが取るであろう値の確率密度分布を事前確率として表現し、データが観測された後にパラメータが取るであろう値の確率密度分布(事後確率密度分布)を推定する。

# Bayesian Spam filter

- Mailwall processing flow [Brightmail02]






# ベイズ推定

---


- パラメータ $\theta$  を確率変数とみなして、パラメータの値の確信度を確率密度分布を用いて表現する。
- データを観測する前にパラメータが取るであろう値の確率密度分布を事前確率として表現し、データが観測された後にパラメータが取るであろう値の確率密度分布(事後確率密度分布)を推定する。

# ベイズ推定

■ データを観測する前にはパラメータがどんな値を取るかに関する情報が得られないので、パラメータの取る値の確率密度分布は、広がった分布となる。



- データが観測されると事後確率密度分布は、データと整合性の良いパラメータほど大きな値を持つような分布となる。
- つまり、事後確率分布は事前確率分布よりも狭い分布となる。



# ベイズ推定


■ N個の学習用データの集合  $X^{(n)} = \{\mathbf{x}^1, \dots, \mathbf{x}^N\}$  から事後確率密度分布  $p(\theta|X)$  が計算できるとする

- 学習用データと同じ分布から特徴ベクトル  $\mathbf{x}$  が得られる確率密度分布は、

$$p(\mathbf{x} | X^{(n)}) = \int p(\mathbf{x}, \theta | X^{(n)}) d\theta$$

- 条件付き確率密度分布の定義から

$$p(\mathbf{x}, \theta | X^{(n)}) = p(\mathbf{x} | \theta, X^{(n)}) p(\theta | X^{(n)}).$$




# ベイズ推定

---

$$p(\mathbf{x}, \theta | X^{(n)}) = p(\mathbf{x} | \theta, X^{(n)}) p(\theta | X^{(n)}).$$

- このとき、 $\mathbf{x}$ はパラメータ $\theta$ のみに依存し、データ $X$ に依存しない。つまり、 $p(\mathbf{x} | \theta, X^{(n)}) \Rightarrow p(\mathbf{x} | \theta)$  とする。
- よって、最初の式は次のようになる。

$$p(\mathbf{x} | X^{(n)}) = \int p(\mathbf{x} | \theta) p(\theta | X^{(n)}) d\theta$$



# ベイズ推定

---

$$p(\mathbf{x} | X^{(n)}) = \int p(\mathbf{x} | \theta) p(\theta | X^{(n)}) d\theta$$

- つまり、ベイズ推定では、パラメータ $\theta$  の特定の値を決める代わりに、すべての可能な値を考え、 $p(\theta | X)$  を重みとした重み付き平均により $x$ の確率密度分布を推定する。

# ベイズ推定とMAP推定

- **ベイズ推定**: 尤度とモデル(パラメータ)の事前確率から、ベイズの定理により、事後確率を推定

$$P(\theta | D) = \frac{P(D | \theta)P(\theta)}{P(D)}$$

ただし、 $P(D) = \int_{\theta'} P(D | \theta')P(\theta')$  ( $\theta$ が連続値の時)

- **最大事後確率(MAP)推定**
  - $P(D|\theta)P(\theta)$  を最大化する  $\theta$  を計算
  - $P(\theta)$  が一様分布なら最尤推定と同じ

# 不正サイコロのベイズ推定

- 公正サイコロと不正サイコロ
  - 公正:  $P(i|\text{公正})=1/6$
  - 不正:  $P(6|\text{不正})=1/2$ ,  $P(i|\text{不正})=1/10$  for  $i \neq 6$
  - $P(\text{公正})=0.99$ ,  $P(\text{不正})=0.01$
- 6が3回続けて出た場合の事後確率

$$\begin{aligned} P(\text{不正} | 666) &= \frac{P(666 | \text{不正})P(\text{不正})}{P(666)} \\ &= \frac{(0.5)^3 (0.01)}{(0.5)^3 (0.01) + (\frac{1}{6})^3 (0.99)} = 0.21 \end{aligned}$$