



ベイズのはなし

ゆっきん

(すうがく徒のつどい 第5回)


前置き

- ゆっきんについて

- 理学部数学科卒→高校数学教師→SE→高校プログラミング講師(NOW)
- 数学と情報の学習コミュニティとボードゲームコミュニティを運営
- QRコードからXアカウントをフォローしていただけると嬉しいです
(仲良くしていただけると、もっと嬉しいです)

- 本講座について

- 本講座はベイズ統計学の入門講演です
- 入門講演として、初学者の方でも楽しめるように心がけます
ぜひ楽しい時間にしましょう！！



目次

1. 条件付き確率とベイズの定理

条件付き確率の復習と、本講座の根幹であるベイズの定理について説明します。

2. 確率分布


ベイズ推論のための準備として、確率分布について説明します。

3. ベイズ推論


コイン投げの例を通して、ベイズ推論の基本的な考え方を説明します。

4. ベイズ線形回帰

ベイズ推論の機械学習への応用として、ベイズ線形回帰を紹介します。



1. 条件付き確率とベイズの定理






根元事象がすべて同様に確からしい試行において、

事象 A の起こる確率は

$$P(A) = \frac{n(A)}{n(U)}$$

事象 A が起こった時に事象 B が起こる条件付き確率は


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



条件付き確率の例

さいころを1回振ります。


出た目が4以上のとき、その目が偶数である確率を求めなさい。




条件付き確率の例

さいころを1回振ります。

出た目が4以上のとき、その目が偶数である確率を求めなさい。



確率は $\frac{2}{3}$



問題「2人の子ども①」


スミスさんには子どもが2人います。2人のうち、**年上の子は女の子**です。
では、2人とも女の子である確率を求めなさい。
ただし、男の子と女の子は等確率で生まれるものと仮定します。

答えはどれでしょうか？

① $\frac{1}{2}$

② $\frac{1}{3}$


③ $\frac{1}{4}$



問題「2人の子ども①」

スミスさんには子どもが2人います。2人のうち、**年上の子は女の子**です。
では、2人とも女の子である確率を求めなさい。
ただし、男の子と女の子は等確率で生まれるものと仮定します。

	年上の子が女の子	年上の子が男の子
年下の子が女の子		
年下の子が男の子		




問題「2人の子ども①」

スミスさんには子どもが2人います。2人のうち、**年上の子は女の子**です。
では、2人とも女の子である確率を求めなさい。
ただし、男の子と女の子は等確率で生まれるものと仮定します。

	年上の子が女の子	年上の子が男の子
年下の子が女の子		
年下の子が男の子		

正解は

$$\textcircled{1} \quad \frac{1}{2}$$



問題「2人の子ども②」

スミスさんには子どもが2人います。2人のうち、**少なくとも1人は女の子**です。

では、2人とも女の子である確率を求めなさい。


ただし、男の子と女の子は等確率で生まれるものと仮定します。

答えはどれでしょうか？

① $\frac{1}{2}$

② $\frac{1}{3}$

③ $\frac{1}{4}$




問題「2人の子ども②」

スミスさんには子どもが2人います。2人のうち、**少なくとも1人は女の子**です。

では、2人とも女の子である確率を求めなさい。

ただし、男の子と女の子は等確率で生まれるものと仮定します。

	年上の子が女の子	年上の子が男の子
年下の子が女の子		
年下の子が男の子		



問題「2人の子ども②」

スミスさんには子どもが2人います。2人のうち、**少なくとも1人は女の子**です。


では、2人とも女の子である確率を求めなさい。

ただし、男の子と女の子は等確率で生まれるものと仮定します。

	年上の子が女の子	年上の子が男の子
年下の子が女の子		
年下の子が男の子		

正解は

$$\textcircled{2} \quad \frac{1}{3}$$




問題「2人の子ども③ 一火曜日に生まれた少女」

スミスさんには子どもが2人います。2人のうち、**少なくとも1人は火曜日に生まれた女の子**です。では、2人とも女の子である確率を求めなさい。

ただし、男の子と女の子は等確率で生まれるものと仮定します。

火曜日に生まれたという一見関係なさそうな条件が、確率に影響を与えるのでしょうか？ ぜひ考えてみてください！

答えは、「火曜日に生まれた少女」と検索すると出てきます。



$P(A \cap B) = P(A) \cdot P(B|A) = P(B) \cdot P(A|B)$ より、

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

この式を**ベイズの定理**と呼びます。


B が何らかの観測、A をその原因としたとき、

$P(A)$: 原因Aの発生確率

$P(B)$: 観測結果Bの発生確率

$P(B|A)$: Aが発生した際に観測結果Bが発生する確率(時間順行)

$P(A|B)$: Bが発生した際に原因Aが起こっていた確率(時間逆行)



問題「病気に罹患している確率」

ある病気の罹患率は1%です。この病気に罹患しているか検査する方法があり、罹患している人は99%の確率で陽性と診断され、健康な人は97%の確率で陰性と診断されます。この検査で陽性と診断されたとき、実際に罹患している確率を求めなさい。

答えはどれでしょうか？

①

25%

②


50%

③

70%

④


99%



問題「病気に罹患している確率」

ある病気の罹患率は1%です。この病気に罹患しているか検査する方法があり、罹患している人は99%の確率で陽性と診断され、健康な人は97%の確率で陰性と診断されます。この検査で陽性と診断されたとき、実際に罹患している確率を求めなさい。


$$P(\text{罹患}|\text{陽性}) = \frac{P(\text{罹患}) \cdot P(\text{陽性}|\text{罹患})}{P(\text{陽性})}$$



問題「病気に罹患している確率」

ある病気の罹患率は1%です。この病気に罹患しているか検査する方法があり、罹患している人は99%の確率で陽性と診断され、健康な人は97%の確率で陰性と診断されます。この検査で陽性と診断されたとき、実際に罹患している確率を求めなさい。

$$\begin{aligned} P(\text{罹患}|\text{陽性}) &= \frac{P(\text{罹患}) \cdot P(\text{陽性}|\text{罹患})}{P(\text{陽性})} \\ &= \frac{\frac{1}{100} \cdot \frac{99}{100}}{\frac{1}{100} \cdot \frac{99}{100} + \frac{99}{100} \cdot \frac{3}{100}} \\ &\quad \text{罹患かつ陽性} \qquad \text{健康かつ陽性} \end{aligned}$$



問題「病気に罹患している確率」

ある病気の罹患率は1%です。この病気に罹患しているか検査する方法があり、罹患している人は99%の確率で陽性と診断され、健康な人は97%の確率で陰性と診断されます。この検査で陽性と診断されたとき、実際に罹患している確率を求めなさい。

$$\begin{aligned} P(\text{罹患}|\text{陽性}) &= \frac{P(\text{罹患}) \cdot P(\text{陽性}|\text{罹患})}{P(\text{陽性})} \\ &= \frac{\frac{1}{100} \cdot \frac{99}{100}}{\frac{1}{100} \cdot \frac{99}{100} + \frac{99}{100} \cdot \frac{3}{100}} \\ &= \frac{1}{4} \end{aligned}$$


罹患かつ陽性 健康かつ陽性

正解は

①

25%

意外と低い！




問題「病気に罹患している確率」

ある病気の罹患率は1%です。この病気に罹患しているか検査する方法があり、罹患している人は99%の確率で陽性と診断され、健康な人は97%の確率で陰性と診断されます。この検査で陽性と診断されたとき、実際に罹患している確率を求めなさい。

<別解>人口を 10000 人と仮定します。

	陽性	陰性
罹患している人(100人)	99人	1人
罹患していない人(9900人)	297人	9603人

$$\frac{99}{99 + 297} = \frac{1}{4}$$



問題「病気に罹患している確率」

ある病気の罹患率は1%です。この病気に罹患しているか検査する方法があり、罹患している人は99%の確率で陽性と診断され、健康な人は97%の確率で陰性と診断されます。この検査で陽性と診断されたとき、実際に罹患している確率を求めなさい。

もともとの病気の罹患率

1%

事前確率

情報追加


検査結果：陽性

情報追加後の病気の罹患率

25%


事後確率

得た情報によって、確率が更新されました。これを**ベイズ更新**といいます。



ベイズの定理の活用例「迷惑メールフィルター」


届いたメールはどのようにして、迷惑メールかどうか判断されるのでしょうか？




ベイズの定理の活用例「迷惑メールフィルター」

届いたメールはどのようにして、迷惑メールかどうか判断されるのでしょうか？


届いたメールが迷惑メールの確率



少ない情報からでも確率を出すことができ、情報が増えるごとに事後確率の精度は高くなっていきます。





2. 確率分布



どの値を取るかが確率的に決まる変数のことを**確率変数**と呼びます。
また、確率を表す関数のことを**確率分布**と呼びます。

(例)コインを2回投げたときの表が出た回数 X


$$P(X) = \begin{cases} \frac{1}{4} & (X = 0) \\ \frac{1}{2} & (X = 1) \\ \frac{1}{4} & (X = 2) \end{cases}$$




連続型の確率変数、確率分布を考えることもできます。

(例)0 から 1 までのランダムな実数 X

- $P(X = 0.5) = 0$ (一点の確率は0)
- $P(0 \leq X \leq 1) = 1$ (全体の確率は1)
- $P(0.4 \leq X \leq 0.6) = 0.2$ (区間の確率は面積)



$f(x) = 1$ ($0 \leq x \leq 1$) を X の**確率密度関数**と呼びます。





確率分布の例① 連続一様分布

確率変数がどのような値でも、確率密度関数が一定の値をとる分布

$$f(x) = \frac{1}{b-a} \quad (a \leq x < b)$$

(例)0 から 1 までの実数をランダムで決定するときの値が従う確率分布





確率分布の例② 正規分布

統計における最重要分布(中心極限定理)

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

μ : 平均
 σ : 標準偏差

(例) 平均50、標準偏差10の正規分布(偏差値)





確率分布の例③ 半正規分布

正の値のみをとる正規分布を考えたい時に使用する分布

σ : 標準偏差

$$f(x) = \sqrt{\frac{2}{\pi\sigma^2}} \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (x > 0)$$

(例) 標準偏差1の半正規分布




確率分布の例④ ベータ分布


α と β の2つのパラメータによって特徴づけられる分布

$$f(x) = C \cdot x^{\alpha-1}(1-x)^{\beta-1} \quad C = \frac{(\alpha + \beta - 1)!}{(\alpha - 1)!(\beta - 1)!}$$


面積を1にする
ための調整係数




$\alpha=1, \beta=1$




$\alpha=2, \beta=1$



$\alpha=1, \beta=2$




$\alpha=2, \beta=2$




$\alpha=3, \beta=2$

連続一様分布




3. ベイズ推論




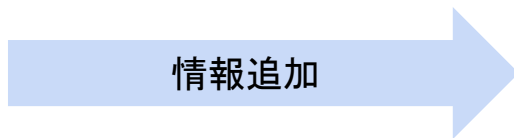
ベイズ推論とは、パラメータ p の確率分布を推論することです。

ベイズ推論の流れは以下となります。


1. パラメータ p の事前の確率分布を設定する(事前分布)
2. 情報が得られる
3. 情報によって、パラメータ p の確率分布が更新される(事後分布)



事前分布




事後分布



問題「くじ引きで当たりを引く確率」

当たりの確率が一定のくじを5回引いたとき、結果は「当たり・外れ・外れ・当たり・外れ」でした。このくじが当たる確率 p はどのくらいでしょうか？

この問題を最尤推定という方法と、ベイズ推論という方法の2通りで考えましょう。



問題「くじ引きで当たりを引く確率」


当たりの確率が一定のくじを5回引いたとき、結果は「当たり・外れ・外れ・当たり・外れ」でした。このくじが当たる確率 p はどのくらいでしょうか？

<最尤推定>


結果が「当たり・当たり・外れ・当たり・外れ」となる確率は、

$$p \cdot (1 - p) \cdot (1 - p) \cdot p \cdot (1 - p) = p^2(1 - p)^3$$

尤度関数



尤度関数が最大となるのは $p = 0.4$ のとき。


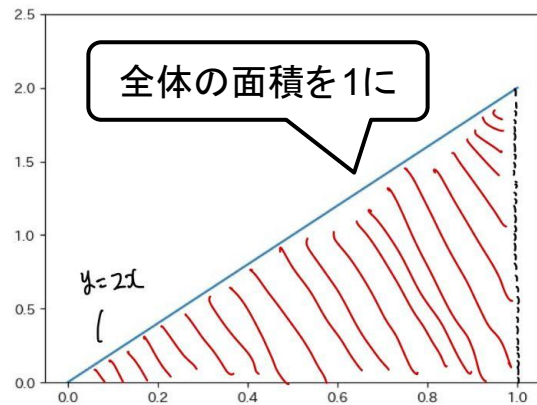

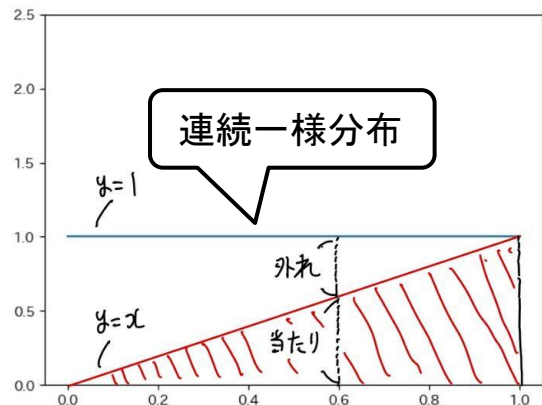


問題「くじ引きで当たりを引く確率」

当たりの確率が一定のくじを5回引いたとき、結果は「当たり・外れ・外れ・当たり・外れ」でした。このくじが当たる確率 p はどのくらいでしょうか？

<ベイズ推論>

p の事前分布として、連続一様分布を考えます。当たりの情報で確率分布が更新されます。


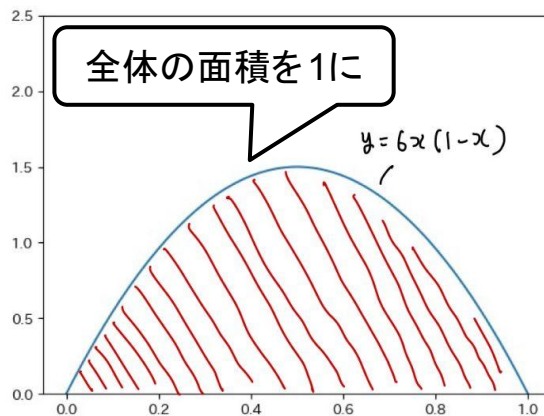




問題「くじ引きで当たりを引く確率」

当たりの確率が一定のくじを5回引いたとき、結果は「当たり・外れ・外れ・当たり・外れ」でした。このくじが当たる確率 p はどのくらいでしょうか？

<ベイズ推論>

次に外れの情報で、また確率分布が更新されます。


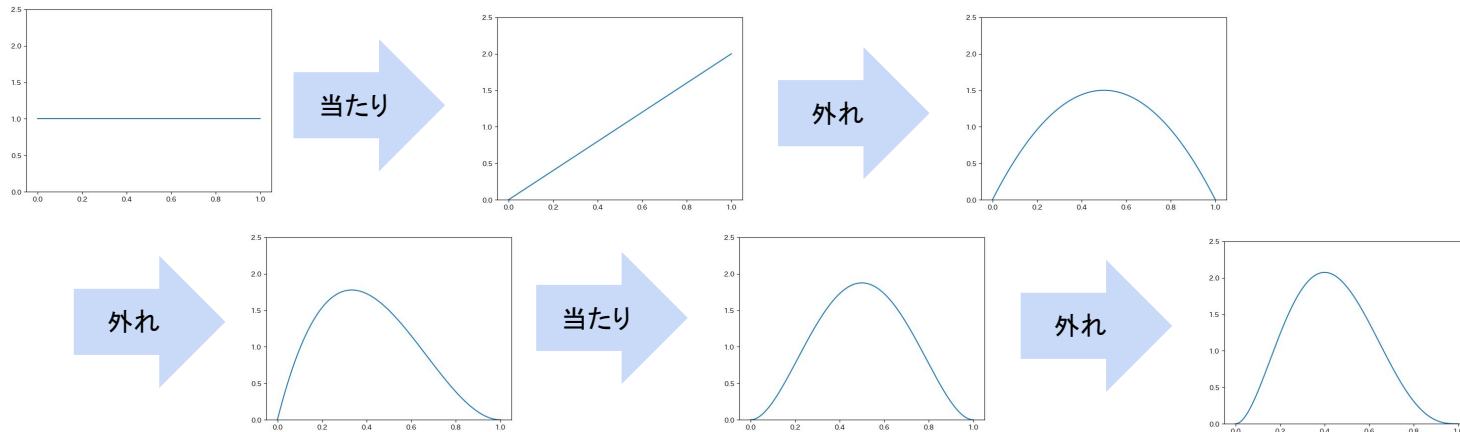


問題「くじ引きで当たりを引く確率」

当たりの確率が一定のくじを5回引いたとき、結果は「当たり・外れ・外れ・当たり・外れ」でした。このくじが当たる確率 p はどのくらいでしょうか？

<ベイズ推論>

同じ流れで、確率分布は以下のように更新されます。

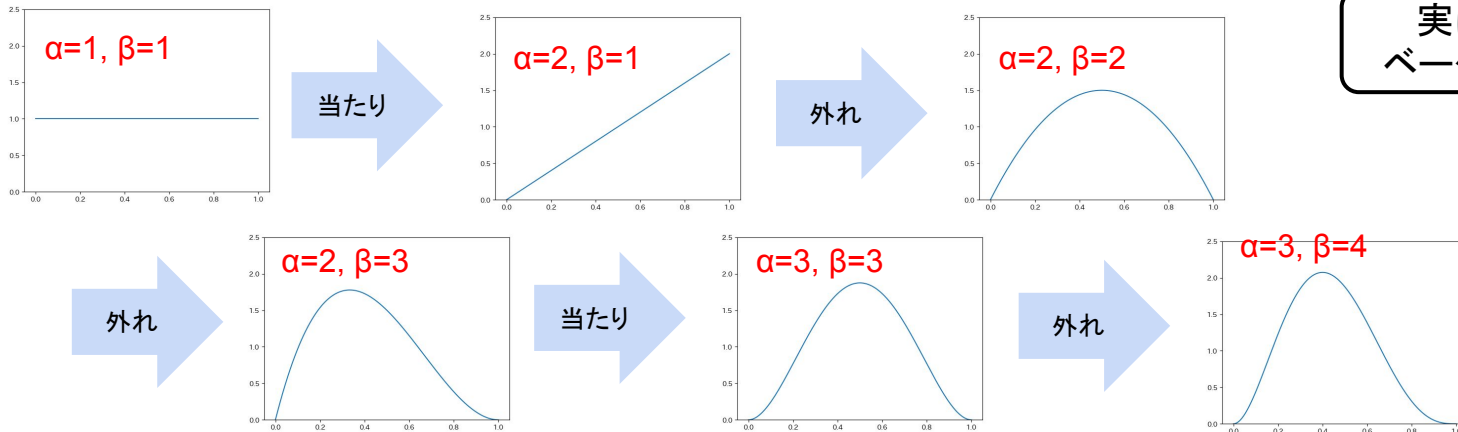


問題「くじ引きで当たりを引く確率」


当たりの確率が一定のくじを5回引いたとき、結果は「当たり・外れ・外れ・当たり・外れ」でした。このくじが当たる確率 p はどのくらいでしょうか？

<ベイズ推論>

同じ流れで、確率分布は以下のように更新されます。




実は全て
ベータ分布！




問題「くじ引きで当たりを引く確率」

当たりの確率が一定のくじを5回引いたとき、結果は「当たり・外れ・外れ・当たり・外れ」でした。このくじが当たる確率 p はどのくらいでしょうか？


今回の場合、最尤推定における尤度関数のグラフと、ベイズ推論で得られる事後分布は同じ形状となりました。



尤度関数のグラフ



ベイズ推論の事後分布




問題「くじ引きで当たりを引く確率」


当たりの確率が一定のくじを5回引いたとき、結果は「当たり・外れ・外れ・当たり・外れ」でした。このくじが当たる確率 p はどのくらいでしょうか？

<ベイズ推論>


p の事前分布として、連続一様分布以外を考えることもできます。




当たり




外れ




外れ




当たり




外れ



$\alpha=6, \beta=6$ の事前分布は、「当たり×5、外れ×5」の事前データを持っていることと同じ


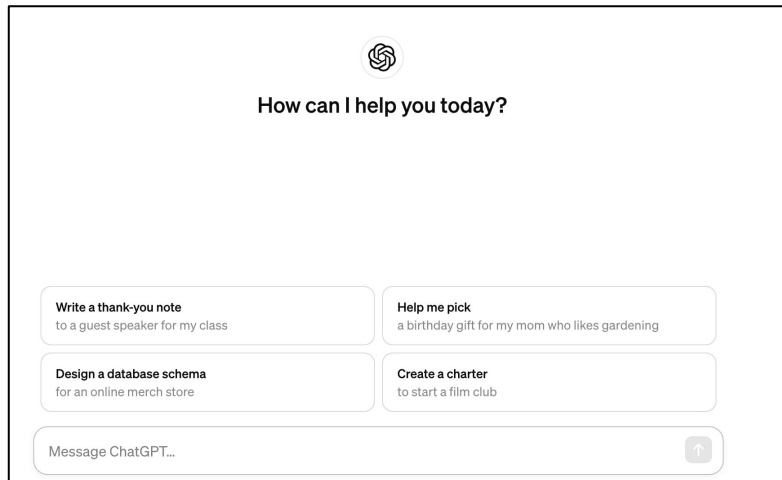


4. ベイズ線形回帰



AI(人工知能)は、**ルールベース**の手法と**機械学習**の手法に分かれます。

- **ルールベースの手法**:人がルールを定める
- **機械学習の手法**:機械(コンピュータ)がデータをもとにルールを学習する





機械学習はさらに教師あり学習、教師なし学習、強化学習に分かれます。

このうち**教師あり学習**とは、正解付きのデータをもとにルールを学習し、未知のデータの正解を予測することを言います。


予測の中でも数値を予測することを、**回帰**と呼びます。

回帰の例 カリフォルニアの住宅価格




回帰の例「カリフォルニアの住宅価格」

住宅の部屋数と住宅価格の関係性を調べてみましょう。



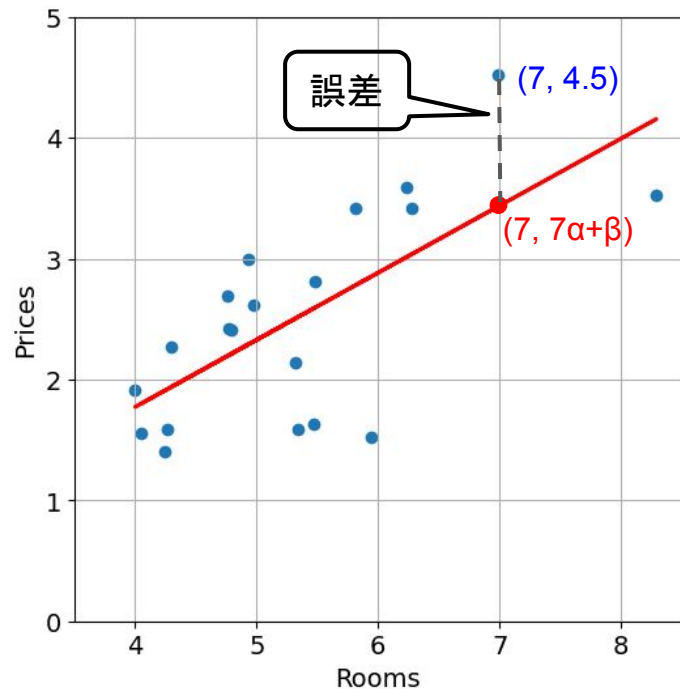
1 次式 $y = \alpha x + \beta$ で 2 変数の関係を近似しましょう。これを**線形回帰**といいます。

最小 2 乗法を用いた一般的な線形回帰と、
ベイズ線形回帰の 2 通りの方法で考えます。



回帰の例「カリフォルニアの住宅価格」


住宅の部屋数と住宅価格の関係性を調べてみましょう。



最小 2 乗法では、直線と各データの y 座標の誤差を調べます。

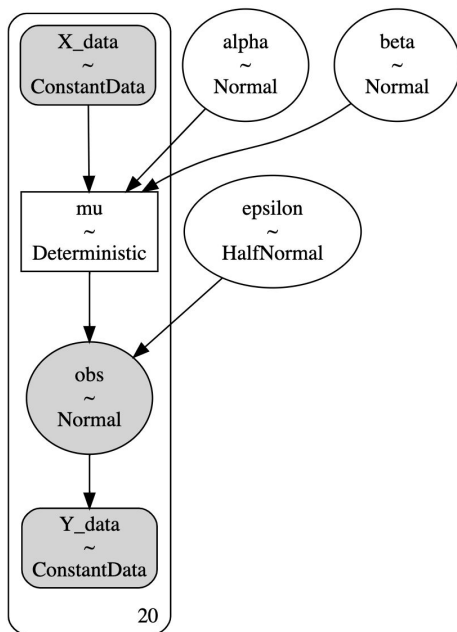
誤差の 2 乗和は α と β の 2 次関数になります。この 2 次関数が最小となる α と β を求めれば OK!

最小 2 乗法では、 α や β が 1 つの値に定まります。



回帰の例「カリフォルニアの住宅価格」


住宅の部屋数と住宅価格の関係性を調べてみましょう。



ベイズ推論とは、パラメータの確率分布を推論することでした。

今回パラメータとして考えるのは次の3種類です。


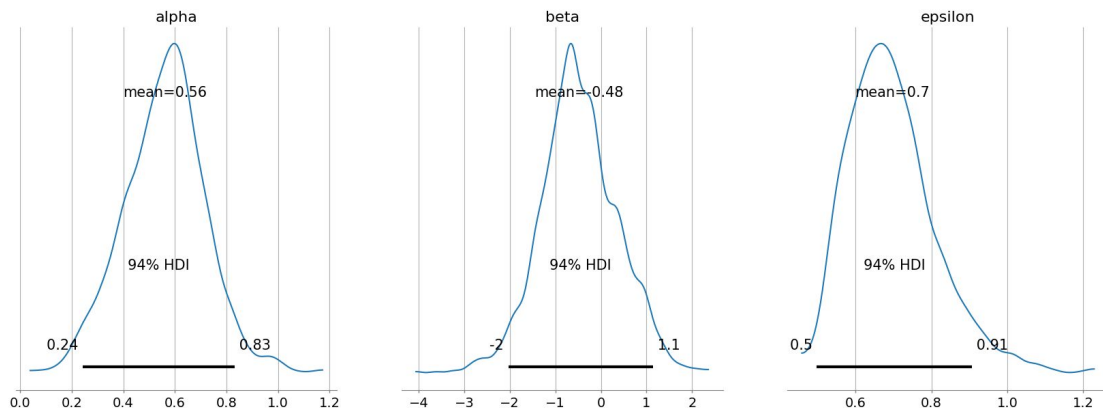
- 傾き α
事前分布は平均値0、標準偏差10の正規分布
- 切片 β
事前分布は平均値0、標準偏差10の正規分布
- 誤差 ε
事前分布は標準偏差1の半正規分布



回帰の例「カリフォルニアの住宅価格」


住宅の部屋数と住宅価格の関係性を調べてみましょう。

情報によって更新された後の α , β , ε の事後分布は次のようになります。
事後分布は通常は解析的に解けない複雑な形をしているため、サンプリングによって近似的に事後分布を求めます。(マルコフチェーンモンテカルロ法 (MCMC))




回帰の例「カリフォルニアの住宅価格」

住宅の部屋数と住宅価格の関係性を調べてみましょう。




ベイズ線形回帰では、 α や β の確率分布が得られますので、それをもとに回帰直線を描くと幅を持った状態で示されます。

これにより、不確実性がどの程度であるかを表現できています。



まとめ

- 確率は情報を得ることで更新されます。(ベイズの定理)
- ベイズ推論は、ベイズの定理を土台とした推論の方法です。パラメータの事前分布と得られたデータをもとに、パラメータの事後分布を推論します。
- ベイズ推論には次のようなメリットがあります
 - 推論の結果が確率分布であることから、不確実性が表現されている
 - データが不十分な場合にも使うことができる
 - 事前知識や経験を事後推定に組み込むことができる



発表は以上となります。

ご清聴ありがとうございました！

