

## L03 2次元正規分布・単回帰

樋口さぶろお

龍谷大学 先端理工学部 数理・情報科学課程

理論物理学特論 L03(2021-10-16 Sat)

最終更新: Time-stamp: "2021-10-12 Tue 16:20 JST hig"

### 今日の目標

- 指定の母平均値と母 (共) 分散の 2 次元正規分布の確率密度関数が書ける



## 再生性 reproductive property

正規分布の再生性 岩薩林 確率・統計定理 4.3

独立な連続型確率変数  $X \sim N(\mu_X, \sigma_X^2)$ ,  $Y \sim N(\mu_Y, \sigma_Y^2)$  に対して,

$$S = aX + bY \sim N(a\mu_X + b\mu_Y, a^2\sigma_X^2 + b^2\sigma_Y^2)$$

特に,


$$S = X + Y \sim N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2)$$

**再生性**とは、独立な確率変数  $X, Y$  の和  $S = X + Y$  が (パラメタは違うけど) 同じ分布 (今なら正規分布) にしたがるという、稀なよい性質。

他に、二項分布, ポアソン分布など。

岩薩林 確率・統計例題 4.14 特定の  $a, b, \mu, \sigma$  での証明

実は、一般の (独立とかぎらない) 2次元正規分布に対しても  $aX + bY$  は1次元正規分布にしたがることになる。



## ここまで来たよ


### 2 2次元の正規分布

- 2次元正規分布 ( $X, Y$  が独立でない)

### 3 線形回帰モデル (単回帰)

- 最尤推定
- 線形回帰モデル
- Jupyter Notebook で実行

## 等高線が傾いた楕円の分布も作りたい!



## 考え方 1

等高線が円  $D = x^2 + y^2$ 等高線が傾いた楕円  $D = x^2 + cxy + 2y^2$ 

2次形式の標準化 (線形代数 I, II)

考え方 2 独立じゃなくしたいから、指数関数の引数に  $xy$  の項でもいれておけば?

## 一般の2次元正規分布

$$f(x, y) = \text{定数}' \times e^{-ax^2 - by^2 + cxy + px + qy}$$

〜

## 一般の2次元正規分布の同時確率密度関数

2次元正規分布  $N(\boldsymbol{\mu}, \Sigma)$  の同時確率密度関数は、確率変数を  $\mathbf{X} = {}^t(X, Y)$  とするとき、

$$f(\mathbf{x}) = \frac{1}{(2\pi)^{2/2} \sqrt{\det \Sigma}} e^{-\frac{1}{2} {}^t(\mathbf{x} - \boldsymbol{\mu}) \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})}$$

$$\text{母平均値 (ベクトル)} \boldsymbol{\mu} = \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix} \stackrel{\text{要証明}}{=} \begin{pmatrix} E[X] \\ E[Y] \end{pmatrix}$$

$$\text{母共分散行列} \Sigma = \begin{pmatrix} \sigma_X^2 & C_{XY} \\ C_{XY} & \sigma_Y^2 \end{pmatrix} \stackrel{\text{要証明}}{=} \begin{pmatrix} V[X] & \text{Cov}[X, Y] \\ \text{Cov}[X, Y] & V[Y] \end{pmatrix}$$

## L03-Q1

## Quiz(2次元正規分布の確率密度関数)

2次元正規分布の同時確率密度関数で,

$$\mu = \begin{pmatrix} -4 \\ 5 \end{pmatrix},$$











$$\Sigma = \begin{pmatrix} 2 & -1 \\ -1 & 3 \end{pmatrix}$$

のとき,


- ① 母平均値, 母(共)分散を答えよう.
- ② 同時確率密度関数  $f$  を(行列やベクトルを使わずに)具体的に書こう.

母相関係数  $r$ , 共分散行列  $\Sigma$ .  $c = \frac{9\sqrt{21}}{10}$  $r = -0.90$  $-0.76$  $0$  $+0.76$  $+0.90$ 

$$\Sigma = \begin{pmatrix} 3 & -c \\ -c & 7 \end{pmatrix}, \begin{pmatrix} 3 & -2\sqrt{3} \\ -2\sqrt{3} & 7 \end{pmatrix}, \begin{pmatrix} 3 & 0 \\ 0 & 7 \end{pmatrix}, \begin{pmatrix} 3 & +2\sqrt{3} \\ +2\sqrt{3} & 7 \end{pmatrix}, \begin{pmatrix} 3 & +c \\ +c & 7 \end{pmatrix}$$



## 2次元正規分布の周辺分布は1次元正規分布



このほか、 $X = x_0$  の条件付き分布、 $S = aX + bY$  の分布も1次元正規分布 → 再生性



## 確率密度関数から母ナントカ I

L03-Q2

### Quiz(2次元正規分布)

次の2変数確率密度関数は2次元正規分布を定める.

$$f(x, y) = C \cdot e^{-2x^2 + 6xy - 7y^2 + 26x - 54y - 7}.$$

- ① 母平均値, 母共分散行列を求めよう.
- ②  $E[1] = 1$  が満たされるように定数  $C$  を定めよう.

## ここまで来たよ

### 2 次元の正規分布

- 2次元正規分布 ( $X, Y$  が独立でない)

### 3 線形回帰モデル (単回帰)

- 最尤推定
- 線形回帰モデル
- Jupyter Notebook で実行

## 線形モデル (統計モデルのある一族)

あるドーナツ製造機の作るドーナツの重さ  $Y$  は次のモデルに従う.

$$Y = \beta_0 + \epsilon, \quad \epsilon \sim N(0, \sigma^2)$$

$Y, \epsilon$ : 連続型確率定数,  $\sigma > 0, \beta_0$ : 定数=パラメタ=母数

$\epsilon$ : 誤差, ノイズ. 小文字だけど確率変数.

(隠された) パラメタ母数  $\mu, \sigma^2$  を,  $n$  個のドーナツの重さのデータから推定したい.

$$E[Y] = \beta_0 + E[\epsilon] = \beta_0,$$

$$V[Y] = V[\epsilon] = \sigma^2.$$

正規分布と限定した以外は, ここしばらくやってた, 母平均値, 母分散の推定の言い換えに過ぎない.

だけど, 多数のパラメタを含む一般的なモデルにも使える考え方をする.

## 尤度 likelihood

$\epsilon = Y - \beta_0 \sim N(0, \sigma^2)$  より, ドーナツの重さ  $y$  を得る確率密度は,

$$f(y|\beta_0, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y-\beta_0)^2}{2\sigma^2}}$$

サイズ  $n$  の標本が  $y_1, \dots, y_n$  である確率密度は, 独立同分布なので積で,

$$\begin{aligned} f(y_1, y_2, \dots, y_n | \beta_0, \sigma) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y_i - \beta_0)^2}{2\sigma^2}} \\ &= (2\pi\sigma^2)^{-n/2} e^{-\sum_{i=1}^n \frac{(y_i - \beta_0)^2}{2\sigma^2}} \end{aligned}$$

### $n$ 次元正規分布

多変量解析及び演習

この  $f$  を,  $y_i$  の確率密度関数と思わず, が測定済データ  $y_1, \dots, y_n$  が定数,  $\beta_0, \sigma$  が変数と思ったとき, **尤度** (ゆうど) 関数  $L(\beta_0, \sigma)$  という。

$$L(\beta_0, \sigma) = f(y_1, y_2, \dots, y_n | \beta_0, \sigma)$$

# 最尤推定

岩薩林 確率・統計なし

## 最尤推定

$\beta_0, \sigma$  の推定値として  $L(\beta_0, \sigma)$  が最大になる値を選ぶ

2変数関数の最大値  $\rightsquigarrow$  偏微分

微積分 II

$$0 = \frac{\partial L}{\partial \beta_0}(\beta_0, \sigma) = \frac{\partial L}{\partial \sigma}(\beta_0, \sigma)$$

ここでは最初の等式だけ解く. 合成微分.

$$0 = (\text{定数})^{-n/2} \times \sum_{i=1}^n \frac{1}{\sigma^2} (y_i - \beta_0) \times e^{\text{同じ}}$$

$$0 = \sum_{i=1}^n (y_i - \beta_0)$$

$$\beta_0 = \frac{1}{n} \sum_{i=1}^n y_i$$

ここでは最初の式だけ.  
合成微分.

$\beta_0$  (母平均値) の最尤推定  
(MLE=maximum likelihood  
estimation) 値  $\hat{\beta}_0$  は **標本平均値**  
**じゃん**

## ここまで来たよ

### 2 2次元の正規分布

- 2次元正規分布 ( $X, Y$  が独立でない)

### 3 線形回帰モデル (単回帰)

- 最尤推定
- 線形回帰モデル
- Jupyter Notebook で実行

## 機械学習としての線形回帰

このドーナツ製造機で作るドーナツの重さ  $Y$  は、温度  $x$  によるらしい。  
次の**線形回帰モデル**を仮定する。

$$Y = \beta_0 + \beta_1 \cdot x + \epsilon, \quad \epsilon \sim N(0, \sigma^2)$$

$Y, \epsilon$ : 連続型確率定数,  $\beta_0, \beta_1$ : **回帰係数**,  $\sigma > 0$ : 定数=パラメタ=母数

$Y$ : **目的変数** (従属変数) ここでは確率変数

$x$ : **説明変数** (独立変数) ここでは確率変数でない

これは教師あり学習の一種

出力が連続的な値, 予測器が 1 次関数。

$(x, y)$  の  $n$  個の訓練データ  $\xrightarrow{\text{学習}}$  パラメタの推定値  $\hat{\beta}_0, \hat{\beta}_1 \rightarrow$  予測器

$$y = f(x) = \hat{\beta}_0 + \hat{\beta}_1 x$$

**性能評価**

機械学習のりなら、訓練データと分けておいたテストデータを使うところだが、統計学のりでは、数学的仮定に基づき、決定係数  $R^2$  で評価 (訓練

# 母平均値の推定と似ている/違う



## (確率変数でない) 変数 $x$ に依存する確率変数 $Y$

永田棟方 多変量解析法入門 §4

このドーナツ製造機で作るドーナツの重さ  $Y$  は、温度  $x$  によるらしい。  
次の線形回帰モデルを仮定する。

$$Y = \beta_0 + \beta_1 \cdot x + \epsilon, \quad \epsilon \sim N(0, \sigma^2)$$

$Y, \epsilon$ : 連続型確率定数,  $\beta_0, \beta_1$ : 回帰係数,  $\sigma > 0$ : 定数 = パラメタ = 母数

$Y$ : 目的変数 (従属変数) ここでは確率変数

$x$ : 説明変数 (独立変数) ここでは確率変数でない

ノイズ・誤差  $\epsilon = Y - \beta_0 + \beta_1 \cdot x \sim N(0, \sigma^2)$ .

$\epsilon = Y - \beta_0 - \beta_1 x \sim N(0, \sigma^2)$  より、ドーナツの重さ  $y$  を得る確率密度は、

$$f(y|x, \beta_0, \beta_1, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y-\beta_0-\beta_1 \cdot x)^2}{2\sigma^2}}$$

(正確に) 指定した温度  $x_i$  ( $i = 1, \dots, n$ ) で製造したときの重さが  $y_i$  ( $i = 1, \dots, n$ ) である確率密度は, 独立分布なので積.

$$\begin{aligned} f(y_1, y_2, \dots, y_n | x_1, \dots, x_n, \beta_0, \beta_1, \sigma) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y_i - \beta_0 - \beta_1 \cdot x_i)^2}{2\sigma^2}} \\ &= (2\pi\sigma^2)^{-n/2} e^{-\sum_{i=1}^n \frac{(y_i - \beta_0 - \beta_1 \cdot x_i)^2}{2\sigma^2}} \\ &= L(\beta_0, \beta_1, \sigma) \end{aligned}$$

## 最尤推定

測定済のデータ  $x_i, y_i$   $i = 1, \dots, n$  を定数と思ったときの, 3 変数関数

$L(\beta_0, \beta_1, \sigma) = f(y_1, y_2, \dots, y_n | x_1, \dots, x_n, \beta_0, \beta_1, \sigma)$  の最大値は?  $\rightsquigarrow$  偏微分 微積分 II

$$0 = \frac{\partial L}{\partial \beta_0}(\beta_0, \beta_1, \sigma) = \frac{\partial L}{\partial \beta_1}(\beta_0, \beta_1, \sigma) = \frac{\partial L}{\partial \sigma}(\beta_0, \beta_1, \sigma)$$

ここでは最初の 2 つの等式だけ解く.

$$0 = \frac{\partial L}{\partial \beta_0} = (\text{定数}) \sum_i \frac{1}{\sigma^2} (y_i - \beta_0 - \beta_1 x_i) \times e^{\text{同じ}}$$

$$0 = \frac{\partial L}{\partial \beta_1} = (\text{定数}) \sum_i \frac{1}{\sigma^2} x_i (y_i - \beta_0 - \beta_1 x_i) \times e^{\text{同じ}}$$

しよせん,  $\beta_0, \beta_1$  の連立 1 次方程式

正規方程式 岩薩林 確率・統計 §9.2

$$\begin{aligned} n\beta_0 + \left(\sum_i x_i\right)\beta_1 &= \sum_i y_i \\ \left(\sum_i x_i\right)\beta_0 + \left(\sum_i x_i^2\right)\beta_1 &= \sum_i x_i y_i \end{aligned}$$

加減法  $\rightsquigarrow$

$$\hat{\beta}_1 = \frac{s_{xy}}{s_{xx}},$$

$$\hat{\beta}_0 = \bar{y} - \frac{s_{xy}}{s_{xx}}\bar{x}$$

$$y = \frac{s_{xy}}{s_{xx}}x + \bar{y} - \frac{s_{xy}}{s_{xx}}\bar{x}$$

$$y - \bar{y} = \frac{s_{xy}}{s_{xx}}(x - \bar{x})$$

ここで,

$$\bar{x} = \frac{1}{n} \sum_i x_i \quad \text{平均値っぽい形}$$

$$\bar{y} = \frac{1}{n} \sum_i y_i \quad \text{平均値っぽい形}$$

$$s_{xy} = \frac{1}{n} \sum_i x_i y_i - \bar{x} \cdot \bar{y} \quad \text{岩薩林 確率・統計定理 1.5} = \frac{1}{n} \sum_i (x_i - \bar{x})(y_i - \bar{y}) \quad \text{共分散っぽい}$$

$$s_{xx} = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 \quad \text{岩薩林 確率・統計定理 1.2} = \frac{1}{n} \sum_i (x_i - \bar{x})^2 \quad \text{分散っぽい}$$

$$Y = \hat{\beta}_0 + \hat{\beta}_1 \cdot x + \epsilon$$


## 回帰直線

岩薩林 確率・統計 §9.1

推定結果  $\beta_0, \beta_1$  を係数とする  $xy$  平面の直線

$$y - \bar{y} = \frac{s_{xy}}{s_{xx}} (x - \bar{x})$$

$\beta_0, \beta_1$  回帰係数



## 回帰係数, 予測値の信頼区間

$Y_i$  は確率変数.

こうやって得られる推定結果を  $\hat{\beta}_0, \hat{\beta}_1$  と書くと, これらも確率変数.  
 $\hat{\beta}_0, \hat{\beta}_1$  にも信頼区間などが考えられる. さらに, (自分が新たに設定した温度  $x$  に対する) 予測値  $\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 x$  にも信頼区間などが考えられる.

## 決定係数

岩薩林 確率・統計 §9.2

残差 直線 (予測値) からの上下方向のずれ,

$$e_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i).$$

決定係数

$$R^2 = 1 - \frac{\sum_i e_i^2}{\sum_i (y_i - \bar{y})^2} = 1 - \frac{\sum_i (y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i))^2}{\sum_i (y_i - \bar{y})^2}$$

$0 \leq R^2 \leq 1$  で,  $1 - R^2$  が 0 に近いほど, あてはまりがよい.


$1 - R^2$  は,  $\frac{\text{予測からのデータのずれ}}{\text{単一平均値 } \bar{y} \text{ からのデータのずれ}}$ , つまり,

$\frac{\text{回帰直線からの誤差}}{\text{平均値からの誤差}}$ .

実は  $R^1$  は, 2 次元データ  $(x_i, y_i)$  の相関係数

岩薩林 確率・統計 p.22

データ分析



岩薩林 確率・統計例題 9.2, 9.3, §9 問題 3,4,5, §9 練習問題 1

## L03-Q3

### Quiz(回帰係数と回帰直線)

$x$  を説明変数,  $y$  を目的変数とする線形モデル  $Y = \beta_0 + \beta_1 \cdot x + \epsilon$ ,  $\epsilon \sim N(0, \sigma^2)$  において,  $x$  を  $x = x_1, \dots, x_n$  と変えて  $Y$  を測定したところ,  $y_1, \dots, y_n$  となった. それをまとめたのが下である.

$$(x, y) \text{ のデータの個数 } n \quad 16$$

$$\bar{x} = \frac{1}{n} \sum_i x_i \quad 9$$

$$\bar{y} = \frac{1}{n} \sum_i y_i \quad -4$$

$$\frac{1}{n} \sum_i x_i^2 - \bar{x}^2 \quad 49$$

$$\frac{1}{n} \sum_i y_i^2 - \bar{y}^2 \quad 36$$

$$\frac{1}{n} \sum_i x_i y_i - \bar{x} \cdot \bar{y} \quad -25$$

このとき, 回帰直線の式を,  $x, y$  で書こう. 整理しなくてよい.



## ここまで来たよ

### 2 次元の正規分布

- 2次元正規分布 ( $X, Y$  が独立でない)

### 3 線形回帰モデル (単回帰)

- 最尤推定
- 線形回帰モデル
- Jupyter Notebook で実行

# Jupyter Notebook で実行

```
[ ] 1 formula='height ~ weight' # formula 表記. ~ の左辺を目的変数, 右辺を説明変数として線形回
2 result=smf.ols(formula, body).fit() # ols = 普通の最小二乗法で fit せよ
3 result.summary() # result に蓄えられた結果を取り出す
```

目的変数は height		OLS Regression Results		決定係数R (Adjusted 自由度調整済)				
<b>Dep. Variable:</b>	height	<b>R-squared:</b>	0.905	<b>Adj. R-squared:</b>	0.904			
<b>Model:</b>	OLS	<b>F-statistic:</b>	935.3	<b>Prob (F-statistic):</b>	6.31e-52			
<b>Method:</b>	Least Squares	<b>AIC:</b>	514.6	<b>BIC:</b>	519.8			
<b>Date:</b>	Sat, 09 Oct 2021	<b>Df Residuals:</b>	98	<b>Df Model:</b>	1			
<b>Time:</b>	00:59:55	<b>Covariance Type:</b>	nonrobust					
<b>No. Observations:</b>	100	<b>coef</b>	<b>std err</b>	<b>t</b>	<b>P&gt; t </b>	<b>[0.025</b>	<b>0.975]</b>	
<b>Df Residuals:</b>	98	Intercept	129.4555	1.122	115.412	0.000	127.230	131.681
<b>Df Model:</b>	1	weight	0.8233	0.027	30.582	0.000	0.770	0.877
<b>Covariance Type:</b>	nonrobust	<b>Omnibus:</b>	1.147	<b>Durbin-Watson:</b>	2.218			
		<b>Prob(Omnibus):</b>	0.564	<b>Jarque-Bera (JB):</b>	1.053			
		<b>Skew:</b>	-0.063	<b>Prob(JB):</b>	0.591			
		<b>Kurtosis:</b>	2.514	<b>Cond. No.</b>	149.			

切片  
説明変数weightの  
係数β1