

# 統計的モデリング基礎②

## ～回帰モデリング～

鹿島久嗣  
(情報学科 計算機科学コース)

DEPARTMENT OF INTELLIGENCE SCIENCE  
AND TECHNOLOGY

# 統計的モデリングの考え方


# 統計モデリングの考え方： 部分から全体について知る

## ■ 母集団：

- ・興味のある集合のすべての要素
- ・確率分布  
(分布のクラスやパラメータで指定される)


## ■ 標本：母集団からの無作為抽出あるいは確率分布に従った抽出

- ・確率変数：確率的に値が決まる変数
- ・標本から母集団について推測する  
(標本抽出の逆)



# 離散型確率変数の代表的な確率分布： 離散分布、ベルヌーイ分布と2項分布

- 离散分布  $P(X = k) = f(k)$  (但し  $\sum_{k \in \mathcal{X}} f(k) = 1, f(k) \geq 0$ )
- ベルヌーイ分布 :  $\mathcal{X} = \{0,1\}$  上の離散分布
- 二項分布
  - ベルヌーイ試行 : 1が出る確率  $p$  の  
ベルヌーイ分布から  $n$  回 独立に抽出する
  - 二項分布 : ベルヌーイ試行において 1 が  $k$  回出る確率を与える



$$P(X = k | p) = \binom{n}{k} p^k (1 - p)^{n-k}$$


- モデルパラメータ  $p$  によって  
分布の形が一意に決定される

$n$  回の試行中のどこで  $k$  回の  
1 が現れるかの場合の数

# 離散型確率変数の代表的な確率分布： ポアソン分布（2項分布の極限）、その他

- ポアソン分布： $P(X = k | \lambda) = \frac{\lambda^k}{k!} \exp(-\lambda)$

- 比較的稀な事象が何回起こるかを表現
  - 1分あたりのWebサーバアクセス数
  - ロットあたりの不良品数
- パラメータ  $\lambda > 0$ 
  - 2項分布のパラメータ  $(n, p)$  がない
  - 2項分布で  $np = \lambda$  として、 $n \rightarrow \infty, p \rightarrow 0$  とするとポアソン分布になる
- ほか、離散型の確率分布には幾何分布、負の2項分布などがある



[https://en.wikipedia.org/wiki/Poisson\\_distribution#/media/File:Poisson\\_pmf.svg](https://en.wikipedia.org/wiki/Poisson_distribution#/media/File:Poisson_pmf.svg)

# 連続型確率変数の代表的な確率分布： 確率密度関数で指定される

- 連続分布は確率密度関数 $f(x)$ で指定される

- 確率 = 確率密度の積分

[ $a, b$ ]内の値をとる確率 :  $P(a \leq X \leq b) = \int_a^b f(x)dx$

- 連続変数がある特定の値をとる確率 :  $P(X = a) = 0$


- $\int_{-\infty}^{\infty} f(x)dx = 1$

- 一様分布：閉区間 $[a, b]$ 上の一様分布は

$$f(x) = \begin{cases} \frac{1}{b-a} & (a \leq x \leq b) \\ 0 & (\text{その他}) \end{cases}$$

# 連続型確率変数の代表的な確率分布： 正規分布

- 正規分布 :  $f(x) = N(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$ 
  - パラメータ : 平均 $\mu$ と分散 $\sigma^2$




- 他、t分布、カイ2乗分布、ガンマ分布、ベータ分布、指數分布など


# 連続型確率変数の代表的な確率分布： 標準正規分布

- $N(\mu, \sigma^2)$ に従う確率変数  $X$  を変数変換 :  $Z = \frac{X-\mu}{\sigma}$
- $Z$  は平均0、標準偏差1の正規分布  $N(0,1)$  に従う

確率密度関数:  $f_X(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$      $\rightarrow$      $f_Z(z) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{z^2}{2}\right)$



標準化  
→



## 確率分布の特性値：

期待値は確率分布の代表値

- 確率変数 $X$ の関数 $g(X)$ の期待値：確率での重みづけ平均

$$E[g(X)] = \begin{cases} \int_{-\infty}^{\infty} g(x) f_X(x) dx & (\text{連続型確率変数}) \\ \sum_{x \in \mathcal{X}} g(x) f_X(x) & (\text{離散型確率変数}) \end{cases}$$

- さまざまな関数 $g(X)$ に対する期待値によって分布の特性を捉える
- 性質：
  - 線形性： $E[ag_1(X) + bg_2(X)] = aE[g_1(X)] + bE[g_2(X)]$
  - イエンセンの不等式： $E[g(X)] \geq g(E[X])$  (ただし $g$ は凸関数)

# さまざまな期待値： 平均と分散

$$g(X) = X$$

- 平均  $\mu = E[X]$  :  $X$  の期待値 (分布の“真ん中”)

$$g(X) = (X - \mu)^2$$


- 分散  $\sigma^2 = \text{Var}(X) = E[(X - \mu)^2]$  :  
平均からの二乗偏差の期待値 (分布の“幅”)

- $\text{Var}(X) = E[X^2] - E[X]^2$
- 標準偏差  $\sigma$  : 分散の正の平方根
  - 正規分布なら  $\mu \pm \sigma$  : 68%,  $\pm 2\sigma$  : 95%,  $\pm 3\sigma$  : 99.7%
- より一般的には (  $k$  次の) モーメント  $E[X^k]$
- 3次モーメント  $\Rightarrow$  歪度、4次モーメント  $\Rightarrow$  尖度 に 関係する
- 例：厳密なサイコロ  $P(X = i) = \frac{1}{6}$  の平均、分散を求めよ

# 平均の推定量： 標本平均

- 標本（部分）から平均（全体の性質）を知りたい
  - 標本  $S = \{x_1, s_2, \dots, x_n\}$
- (母) 平均はどのように推定できる？
- 標本平均 :  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  を平均  $\mu = E[X]$  の推定値として使う？
  - 直感的には妥当そうだが、他にも候補は考えられるはず
    - $x_n$  でもよいかもしれないし、適当に選んだ3つの値の中央値でもよいかもしれない...
    - 「よい」とか「よくない」は、どのように評価できるだろうか？

# 推定量としての標本平均の好ましさ： 標本平均は不偏性と一致性をもつ

- 標本平均は平均の推定値として好ましいか？
- 不偏性  $E_S[\bar{X}] = \mu$ ：標本平均の期待値は母集団の平均に一致する
  - $E_S$ は標本についての期待値（何度も標本をとり直して、何度も標本平均を求めたときの、それらの平均）
- 一致性：標本サイズが大きくなるほど母集団の平均  $\mu$  に近づく
  - 標本平均の分散  $\text{Var}_S[\bar{X}] = \frac{\sigma^2}{n} \xrightarrow{n \rightarrow \infty} 0$  （大数の法則）  
 $(= E_S[(\bar{X} - \mu)^2])$ 

σ<sup>2</sup>は母分散

# 推定量としての標本平均の好ましさ： 標本平均はBLUE（最良な線形不偏推定量）

- 効率性：推定値の分散が小さいこと

- 標本平均  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  の代わりに最初の値を使う  $\tilde{x} = x_1$  とする
- 標本平均のほうが「効率的」
  - 標本平均の分散  $\frac{\sigma^2}{n} <$  最初の値の分散  $\sigma^2$
- BLUE（最良な線形不偏推定量）：加重平均で表されるすべての不偏推定量の中で、最も分散が小さい（効率的）なもの
  - 加重平均による推定量  $\hat{x} = \frac{1}{n} \sum_{i=1}^n a_i x_i$

# 分散の推定量： 不偏分散

- 標本分散 :  $\frac{(x^{(1)} - \bar{x})^2 + \cdots + (x^{(n)} - \bar{x})^2}{n} = \frac{1}{n} \sum_{i=1}^n (x^{(i)} - \bar{x})^2$
- 不偏性をもたない :  $E_S \left[ \frac{1}{n} \sum_{i=1}^n (X^{(i)} - \bar{X})^2 \right] = \frac{n-1}{n} \sigma^2$
- 不偏分散 :  $\frac{1}{\textcolor{red}{n-1}} \sum_{i=1}^n (x^{(i)} - \bar{x})^2$ 
  - 不偏性をもつ : 期待値が母集団の分散に一致する
- どちらも一致性はもつ :
  - 標本サイズが大きくなるほど母集団の分散に近づく
  - $n$ が大きいところでは  $n$  も  $n - 1$  も大した違いはない

# 回帰

# 回帰：

片方の変数でもう片方の変数を説明

- 相関 (correlation) は二変数  $x, y$  を区別せずに対等に扱う
  - 一方が増えたときに他方が増える(減る) 関係性を調べる
  - 例：身長と体重
- 回帰 (regression) は変数  $x$  で変数  $y$  を説明する
  - 一方から他方が決定される様子や程度を調べる
  - 例：年齢と血圧、所得と消費
  - $x$ を独立変数・説明変数、 $y$ を従属変数・応答変数などとよぶ

# 回帰の問題：

片方の変数からもう片方を説明するモデルをデータから推定

- 2つの変数  $x$  と  $y$  の組について  $N$  組のデータがある

- $\mathbf{x} = (x^{(1)}, x^{(2)}, \dots, x^{(n)})$  と  $\mathbf{y} = (y^{(1)}, y^{(2)}, \dots, y^{(n)})$

- $y$  を  $x$  で説明（予測）するモデル  $g$  がほしい

- 概ね  $y = g(x)$  となる  $g$


- 例えば直線を  $g$  として仮定

- $g$  の使い道：

- 予測


- 因果関係の発見  
(ただし注意が必要)

国家公務員数 vs 特定独立行政法人職員数



# 基本的な回帰モデル： 線形回帰モデル

- 線形モデル：  $y = g(x) = \beta x + \alpha$ 
  - $\beta$ ：傾きパラメータ ( $x$ が1増えると、 $y$ が1増える)
  - $\alpha$ ：切片パラメータ
- $x$ と $y$ の間に直線的な関係を仮定する
  - $y$ が $x$ の線形関数に依存



# 回帰モデルのパラメータ推定問題の定式化： モデルとデータの食い違いを最小化する最小二乗法

- データ :  $\mathbf{x} = (x^{(1)}, x^{(2)}, \dots, x^{(n)})$  と  $\mathbf{y} = (y^{(1)}, y^{(2)}, \dots, y^{(n)})$
- モデルの出力する予測値 :  $\hat{y}^{(i)} = \beta x^{(i)} + \alpha$
- モデルの予測と実際のデータとの食い違いを定義する :

$$\ell(\alpha, \beta) = \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2 = \sum_{i=1}^n (y^{(i)} - (\beta x^{(i)} + \alpha))^2$$

- 食い違いを二乗誤差で測る
- 最適化問題（最小化）：  
 $(\hat{\alpha}, \hat{\beta}) = \operatorname{argmin}_{\alpha, \beta} \ell(\alpha, \beta)$

# 最小二乗法の解： 二乗誤差を最小化する解

- $\ell(\alpha, \beta)$ を $\alpha$ と $\beta$ で偏微分して0とおいて、解くと：

$$\hat{\beta} = \frac{\sum_i (x^{(i)} - \bar{x})(y^{(i)} - \bar{y})}{\sum_i (x^{(i)} - \bar{x})^2} = \frac{S_{xy}}{S_{xx}}$$

$$\hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}$$

- $x$ と $y$ の共分散： $S_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x^{(i)} - \bar{x})(y^{(i)} - \bar{y})$
- $x$ の不偏分散： $S_{xx} = \frac{1}{n-1} \sum_{i=1}^n (x^{(i)} - \bar{x})^2$

# 最小二乗法の性質： 不偏性と推定精度

- いくつかの仮定の下で不偏性をもつ
  - 母集団において  $\epsilon^{(i)} = y^{(i)} - (\beta^* + \alpha^* x^{(i)})$  が同一の分布に従い一定の分散  $\sigma^2$ 、互いに無相関、 $\epsilon_i$  と  $x_i$  が無相関などの仮定
  - 不偏性 :  $E[\hat{\beta}] = \beta^*$ ,  $E[\hat{\alpha}] = \alpha^*$  (標本の取り方についての期待値)
- $Var[\hat{\beta}] = \frac{\sigma^2}{\sum_{i=1}^n (x^{(i)} - \bar{x})^2}$  : 広範囲の  $x^{(i)}$  があったほうが精度がよい
- $Var[\hat{\alpha}] = \sigma^2 \left( \frac{1}{n} + \frac{\bar{x}}{\sum_{i=1}^n (x^{(i)} - \bar{x})^2} \right)$  : 原点付近の  $x^{(i)}$  があったほうが精度がよい

## 決定係数：

従属変数をモデルがどの程度説明できたかを測る

- 決定係数  $R^2$  : モデルの予測値  $\hat{\mathbf{y}} = (\hat{y}^{(1)}, \hat{y}^{(2)}, \dots, \hat{y}^{(n)})$  とデータ  $\mathbf{y} = (y^{(1)}, y^{(2)}, \dots, y^{(n)})$ との相関係数の2乗

$$R^2 = \frac{\left(\sum_{i=1}^n (\hat{y}^{(i)} - \bar{y})(y^{(i)} - \bar{y})\right)^2}{\left(\sum_{i=1}^n (\hat{y}^{(i)} - \bar{y})^2\right) \left(\sum_{i=1}^n (y^{(i)} - \bar{y})^2\right)} = \frac{\sum_{i=1}^n (\hat{y}^{(i)} - \bar{y})^2}{\sum_{i=1}^n (y^{(i)} - \bar{y})^2}$$

- $\mathbf{y} = (y^{(1)}, y^{(2)}, \dots, y^{(n)})$  の変動（分母）のうち、回帰式が説明できる変動（分子）の割合
- 相関係数は  $-1 \leq R \leq 1$  なので、決定係数  $0 \leq R^2 \leq 1$
- 決定係数が 1 に近いほどデータへのモデルの当てはまりがよい

# 決定係数：

従属変数をモデルがどの程度説明できたかを測る

## ■ $y$ の変動の分解：

$$\sum_{i=1}^n (y^{(i)} - \bar{y})^2 = \sum_{i=1}^n (\hat{y}^{(i)} - \bar{y})^2 + \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2$$

$y$  の変動

回帰式の予測  $\hat{y}^{(i)}$   
が説明できる変動

残差の平方和  
 $\sum_{i=1}^n \epsilon^{(i)2}$

$$\underbrace{\sum_{i=1}^n (\hat{y}^{(i)} - \bar{y})^2}_{\text{回帰による説明}} + \underbrace{\sum_{i=1}^n \epsilon^{(i)2}}_{\text{回帰後に残るばらつき}}$$



$$\underbrace{\sum_{i=1}^n (\hat{y}^{(i)} - \bar{y})^2}_{\text{回帰による説明}} + \underbrace{\sum_{i=1}^n \epsilon^{(i)2}}_{\text{回帰後に残るばらつき}}$$

回帰による説明

回帰後に残るばらつき

回帰による説明

回帰後に残るばらつき



# 課題：

## 回帰モデリングを試してみよう！

- 自分でデータを見つけよう！

- 従属変数と独立変数を決めよう！

- データ： $\mathbf{x} = (x^{(1)}, x^{(2)}, \dots, x^{(n)})$  と  $\mathbf{y} = (y^{(1)}, y^{(2)}, \dots, y^{(n)})$

- 回帰モデルを推定してみよう！ $: \hat{y}^{(i)} = \beta x^{(i)} + \alpha$

$$\hat{\beta} = \frac{\sum_i (x^{(i)} - \bar{x})(y^{(i)} - \bar{y})}{\sum_i (x^{(i)} - \bar{x})^2}, \quad \hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}$$

- 決定係数を計算、データと回帰モデルをプロットしてみよう！



- 推定に使用しないデータに対しても、予測を評価してみよう

## まとめ： 回帰モデリング

- 回帰では、（1個ないし複数の）独立変数から従属変数を説明・予測するモデルを作る
- 線形回帰モデル：独立変数が線形に効くモデル
- 最小二乗法によって回帰モデルのパラメータが求まる
- モデルの当てはまりは決定係数によって測る