

# 統計モデル

## 統計モデル


- ばらつきや誤差を含むデータの背後にある規則性, データを発生させる仕組みを数式で表したもの
- 観測誤差を含む観測データから背後にある現象を分析・予測

## 統計モデル

- コインを投げて表が出る確率を $\theta$ として,  
 $N$ 回コインを投げたときに $y$ 回表が出る確率

$$P(y|N, \theta) = {}_N C_y \theta^y (1 - \theta)^{N - y}$$

- 二項分布モデル
- $\theta = 0.5$
- $N = 10$




# 統計モデル

- 1時間に平均 $\lambda$ 人の客が来る窓口に、1時間に $y$ 人の客が来る確率

$$P(y) = \frac{\lambda^y e^{-\lambda}}{y!}$$

- ポアソン分布モデル
- $\lambda = 5$



## 統計モデル


- 単位面積当たりの給水量 ( $x$ ) に対して、植物の収穫量 ( $y$ ) が、平均  $\beta_0 + \beta_1 x$ 、分散  $\sigma^2$  (標準偏差  $\sigma$ ) の正規分布にしたがう
- 給水量  $x$  のときに収穫量  $y$  の確率密度

$$f(y) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[ -\frac{\{y - (\beta_0 + \beta_1 x)\}^2}{2\sigma^2} \right]$$

# 統計モデル

- $y$ が、平均  $\beta_0 + \beta_1 x$ 、分散  $\sigma^2$  (標準偏差  $\sigma$ ) の正規分布にしたがう

$y \simeq \beta_0 + \beta_1 x$   
と近似



# 統計モデル


## モデルの構築

1. データの背後にある規則性, データを発生させる仕組みを関数で表す
  - 関数の型式は決まる / パラメタの値はわからない
2. 観測データと照らし合わせて最も適切なパラメタの決定 (推定)
  - 非線形の最適化
3. モデルの評価, 修正

# 統計モデル

- $y$ が、平均  $\beta_0 + \beta_1 x$ 、分散  $\sigma^2$  (標準偏差  $\sigma$ ) の正規分布にしたがう

$y \simeq \beta_0 + \beta_1 x$   
と近似





# 統計モデル

## モデルの構築


1. データの背後にある規則性，データを発生させる仕組みを関数で表す
  - 関数の型式は決まる／パラメタの値はわからない
2. 観測データと照らし合わせて最も適切なパラメタの決定 (推定)
  - 非線形の最適化
3. モデルの評価，修正

# 最小二乗法によるパラメタ推定

# 最小二乗法によるパラメタ推定

## 線形単回帰モデル


- 1日の最高気温  $T$  とビールの販売量  $Y$  の関係



# 最小二乗法によるパラメタ推定

## 線形単回帰モデル

- 1日の最高気温  $T$  とビールの販売量  $Y$  の関係



# 最小二乗法によるパラメタ推定

## 線形単回帰モデル

- 1日の最高気温  $T$  とビールの販売量  $Y$  の間に近似的に直線関係が成り立ちそう

$$Y = \beta_0 + \beta_T T$$

- 原因となる変数 … 説明変数
- 結果となる変数 … 目的変数
- 説明変数と目的変数を結びつけるモデル … 回帰モデル

# 最小二乗法によるパラメタ推定

## 線形単回帰モデル

- 説明変数  $T$  と目的変数  $Y$  の間に近似的に

$$Y = \beta_0 + \beta_T T$$

が成り立つと仮定

- $n$  個の  $Y$  の測定値を  $Y_1, Y_2, \dots, Y_n$ ,  
対応する  $T$  の値を各々  $T_1, T_2, \dots, T_n$


$$Y_i = \beta_0 + \beta_T T_i + \varepsilon_i$$

- $\varepsilon_i$  は直線近似した時の誤差（残差）

# 最小二乗法によるパラメタ推定

## 線形単回帰モデル

- 各  $\varepsilon_i$  が 0 に近いほど直線がよく当てはまっている



# 最小二乗法によるパラメタ推定

## 線形単回帰モデル

- 各  $\varepsilon_i$  が 0 に近いほど直線がよく当てはまっている

$$J(\beta_0, \beta_T) = \sum_{i=1}^n \varepsilon^2 = \sum_{i=1}^n \{Y_i - (\beta_0 + \beta_T T_i)\}^2$$

が最小になるようにパラメタ  $\beta_0, \beta_T$  を決定

… 最小二乗法



# 最小二乗法によるパラメタ推定

## 線形単回帰モデル

$$J(\beta_0, \beta_T) = \sum_{i=1}^n \varepsilon^2 = \sum_{i=1}^n \{Y_i - (\beta_0 + \beta_T T_i)\}^2$$

を最小とする  $\beta_0, \beta_T$  を決定

- $J$  が最小になるためには,

$$\nabla J(\beta_0, \beta_T) = \mathbf{0}$$

# 最小二乗法によるパラメタ推定

## 線形単回帰モデル

$$\frac{\partial J}{\partial \beta_0} = 2n\beta_0 - 2\sum_{i=1}^n Y_i + 2\beta_T \sum_{i=1}^n T_i = 0$$

$$\frac{\partial J}{\partial \beta_T} = 2\beta_T \sum_{i=1}^n T_i^2 - 2\sum_{i=1}^n T_i Y_i + 2\beta_0 \sum_{i=1}^n T_i = 0$$

$$\beta_0 = \frac{\sum_{i=1}^n T_i^2 \sum_{i=1}^n Y_i - \sum_{i=1}^n T_i Y_i \sum_{i=1}^n T_i}{n \sum_{i=1}^n T_i^2 - (\sum_{i=1}^n T_i)^2}, \quad \beta_T = \frac{n \sum_{i=1}^n T_i Y_i - \sum_{i=1}^n T_i \sum_{i=1}^n Y_i}{n \sum_{i=1}^n T_i^2 - (\sum_{i=1}^n T_i)^2}$$

# 最小二乗法によるパラメタ推定

## 線形単回帰モデル

$$J(\beta_0, \beta_T) = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n \{Y_i - (\beta_0 + \beta_T T_i)\}^2$$

を最小とする  $\beta_0, \beta_T$  を決定

# 最小二乗法によるパラメタ推定

## 線形重回帰モデル

- 1日の最高気温 $T$ 、降水量 $R$ とビールの販売量 $Y$ の間に近似的に


$$Y = \beta_0 + \beta_T T + \beta_R R$$

が成り立つ

# 最小二乗法によるパラメタ推定

## 線形重回帰モデル

- 1日の最高気温  $T$ ,  
降水量  $R$  とビールの  
販売量  $Y$  との関係



# 最小二乗法によるパラメタ推定

## 線形重回帰モデル

- $p$ 個の説明変数  $x_1, x_2, \dots, x_p$  を用いて, 近似的に

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

が成り立つと仮定

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \varepsilon_i$$

- 複数の説明変数からなる線形回帰モデル  
… (線形) 重回帰モデル

# 最小二乗法によるパラメタ推定

## 線形重回帰モデル

- 重回帰モデルのパラメタ  $\beta_0, \beta_1, \dots, \beta_p$  は

$$J(\boldsymbol{\beta}) = \sum_{i=1}^n \{y_i - (\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip})\}^2$$

を最小化する最小二乗法で求められる

- $\nabla J(\boldsymbol{\beta}) = \mathbf{0}$  を解くと,  $\beta_0, \beta_1, \dots, \beta_p$  が求められる

# 最小二乗法によるパラメタ推定

## 線形重回帰モデル

$$\mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ & & & \ddots & \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix}$$

$$\mathbf{y} = [y_1, y_2, \cdots, y_n]^T, \quad \boldsymbol{\beta} = [\beta_0, \beta_1, \cdots, \beta_p]^T$$

$$\boldsymbol{\varepsilon} = [\varepsilon_1, \varepsilon_2, \cdots, \varepsilon_n]^T$$

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$



# 最小二乗法によるパラメタ推定

## 線形重回帰モデル

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

$$J(\boldsymbol{\beta}) = \sum_{i=1}^n \varepsilon_i^2 = \boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon} = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})$$

$$\nabla J(\boldsymbol{\beta}) = -2\mathbf{X}^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) = \mathbf{0}$$

を解くと

$$\boldsymbol{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

# 最小二乗法によるパラメタ推定

## モデルの評価

$$\beta = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

- $\mathbf{X}$  を構成するベクトルが線形従属  
= 1つの説明変数が他の説明変数の線形和  
…  $\mathbf{X}^T \mathbf{X}$  が逆行列を持たない
- 線形従属に近い状態 … パラメタが不安定
- 説明変数が冗長
- 分散拡大要因 (variance inflation factor; VIF),  
トレランス (tolerance)

# 最小二乗法によるパラメタ推定

## モデルの評価


- 測定値  $y$  と推定値  $Y = X\beta$  の相関係数 (重相関係数)

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}$$


- $-1 \leq R \leq 1$  … 増減をともにする程度
- 決定係数  $R^2$  …  $y$  の変動をモデルで説明できる割合

# 最小二乗法によるパラメタ推定

## モデルの評価



$$R^2 = 0.94$$



$$R^2 = 0.64$$

# 最小二乗法によるパラメタ推定

## モデルの評価

- $-1 \leq R \leq 1$  … 増減をともにする程度
- 決定係数  $R^2$  …  $y$ の変動をモデルで説明できる割合
- 説明変数の数が多いほど  $R^2$ は大きい  
… 説明変数が多過ぎると予測精度低下
- 自由度調整済み決定係数


$$\bar{R}^2 = 1 - \frac{n-1}{n-p-1}(1-R^2)$$

説明変数の数をペナルティ

# 最小二乗法によるパラメタ推定

## 非線形回帰モデル

- 1日の最高気温  $T$  とビールの販売量  $Y$  の関係






# 最小二乗法によるパラメタ推定

## 非線形回帰モデル

- 1日の最高気温  $T$  とビールの販売量  $Y$  の関係







# 最小二乗法によるパラメタ推定

## 非線形回帰モデル

- $Y$  と  $T$  の間に近似的に

$$Y = f(T|\boldsymbol{\beta})$$

が成り立つと仮定

- $\boldsymbol{\beta}$  はパラメタのベクトル
- $n$  個の  $Y$  の測定値を  $Y_1, Y_2, \dots, Y_n$ ,  
対応する  $T$  の値を各々  $T_1, T_2, \dots, T_n$

$$Y_i = f(T_i|\boldsymbol{\beta}) + \varepsilon_i$$



# 最小二乗法によるパラメタ推定

## 非線形回帰モデル

$$Y_i = f(T_i|\beta) + \varepsilon_i$$

- パラメタ  $\beta$  は線形回帰モデルの場合と同様に

$$J(\beta) = \sum_{i=1}^n \{Y_i - f(T_i|\beta)\}^2$$

を最小化する最小二乗法で求めることができる


- 一般にはニュートン法などの非線形最適化法を用いて数値的に解を求める

# 最小二乗法によるパラメタ推定

## 非線形回帰モデル

$$Y = f(T|\boldsymbol{\beta}) = \beta_1 \exp\left(-\frac{(T - \beta_2)^2}{\beta_3^2}\right)$$

$$Y_i = \beta_1 \exp\left(-\frac{(T_i - \beta_2)^2}{\beta_3^2}\right) + \varepsilon_i$$



## 最小二乗法によるパラメタ推定

$$J(\boldsymbol{\beta}) = \sum_{i=1}^n \varepsilon^2 = \sum_{i=1}^n \left\{ Y_i - \beta_1 \exp \left( -\frac{(T_i - \beta_2)^2}{\beta_3^2} \right) \right\}^2$$

$$\nabla J(\boldsymbol{\beta}) = \left[ \frac{\partial J}{\partial \beta_1} \quad \frac{\partial J}{\partial \beta_2} \quad \frac{\partial J}{\partial \beta_3} \right]^T$$

$$\nabla^2 J(\boldsymbol{\beta}) = \begin{bmatrix} \frac{\partial^2 J}{\partial \beta_1^2} & \frac{\partial^2 J}{\partial \beta_1 \partial \beta_2} & \frac{\partial^2 J}{\partial \beta_1 \partial \beta_3} \\ \frac{\partial^2 J}{\partial \beta_2 \partial \beta_1} & \frac{\partial^2 J}{\partial \beta_2^2} & \frac{\partial^2 J}{\partial \beta_2 \partial \beta_3} \\ \frac{\partial^2 J}{\partial \beta_3 \partial \beta_1} & \frac{\partial^2 J}{\partial \beta_3 \partial \beta_2} & \frac{\partial^2 J}{\partial \beta_3^2} \end{bmatrix}$$

# 最小二乗法によるパラメタ推定

## 非線形回帰モデル

- $\nabla J(\beta)$  の計算

$$\frac{\partial}{\partial \beta_1} J(\beta_1, \beta_2, \beta_3) = \lim_{\Delta \rightarrow 0} \frac{J(\beta_1 + \Delta, \beta_2, \beta_3) - J(\beta_1, \beta_2, \beta_3)}{\Delta}$$


- $\Delta$  を 0 に近い数として差分近似

$$\frac{\partial}{\partial \beta_1} J(\beta_1, \beta_2, \beta_3) \simeq \frac{J(\beta_1 + \Delta, \beta_2, \beta_3) - J(\beta_1, \beta_2, \beta_3)}{\Delta}$$

# 最小二乗法によるパラメタ推定

## 非線形回帰モデル

$$y = \beta_1 \exp\left(-\frac{(T - \beta_2)^2}{\beta_3^2}\right)$$



T



# 最尤推定法によるパラメタ推定

# 最尤推定法によるパラメタ推定

ゆうど

## 尤度 (尤度関数)

- ある統計モデル  $f(y|\boldsymbol{\theta})$  を仮定しているときに、特定の観測データが得られる確率 (確率密度)

$$p(y_1, y_2, \dots, y_n | \boldsymbol{\theta}) = \prod_{i=1}^n f(y_i | \boldsymbol{\theta})$$

- パラメタ  $\boldsymbol{\theta}$  の関数

$$L(\boldsymbol{\theta} | y_1, y_2, \dots, y_n) = \prod_{i=1}^n f(y_i | \boldsymbol{\theta})$$

# 最尤推定法によるパラメタ推定

## 最尤推定法

- 尤度（尤度関数）

$$L(\boldsymbol{\theta}|y_1, y_2, \dots, y_n) = \prod_{i=1}^n f(y_i|\boldsymbol{\theta})$$

- 観測データに統計モデルが「どれくらいあてはまっているか」を表す尺度
- 最尤推定法では，観測データのもとで尤度が最大になるようにパラメタ値を決定

## 最尤推定法によるパラメタ推定


- 材料は温度を上げると化学的特性が変化
- 加熱温度  $x$  ( $^{\circ}\text{C}$ ), サンプル数  $N$  (個), そのうち特性が変化したサンプル数  $y$  (個)
- 加熱温度と特性が変化する確率の関係を求めよ

$i$	1	2	3	4	5	6	7	8
$x_i$	100	120	140	160	180	200	220	240
$N_i$	96	99	99	97	100	98	99	100
$y_i$	12	21	36	61	79	83	95	99

# 最尤推定法によるパラメタ推定

## ロジスティック回帰モデル


- 加熱温度  $x$  ( $^{\circ}\text{C}$ )
- サンプル数  $N$  (個)
- 特性が変化した  
サンプル数  $y$  (個)



# 最尤推定法によるパラメタ推定

## ロジスティック回帰モデル

$$\begin{aligned} p(x|\beta_0, \beta_1) &= \frac{\exp(\beta_0 + \beta_1 x)}{1 + \exp(\beta_0 + \beta_1 x)} \\ &= \frac{1}{1 + \exp\{-(\beta_0 + \beta_1 x)\}} \end{aligned}$$



# 最尤推定法によるパラメタ推定

## ロジスティック回帰モデル

- 加熱温度が  $x_i$  ( $^{\circ}\text{C}$ ) のときに  $N_i$  個のサンプル中  $y_i$  個の特性が変化する確率は二項分布にしたがう

$$P(y_i|x_i, N_i, P_i) = {}_{N_i}C_{y_i} P_i^{y_i} (1 - P_i)^{N_i - y_i}$$
$$P_i = p(x_i|\beta_0, \beta_1) = \frac{1}{1 + \exp\{-(\beta_0 + \beta_1 x)\}}$$

- $N_i$  個の中から  $y_i$  個を選ぶ組み合わせの数

$${}_{N_i}C_{y_i} = \binom{N_i}{y_i} = \frac{N_i!}{(N_i - y_i)! y_i!}$$

# 最尤推定法によるパラメタ推定

## ロジスティック回帰モデル

- $i = 1, 2, \dots, n$  ( $n = 8$ )において、加熱温度が  $x_i$  ( $^{\circ}\text{C}$ ) のときに  $N_i$  個のサンプル中  $y_i$  個の特性が変化する確率

$$f(y_1, y_2, \dots, y_n | \beta_0, \beta_1) = \prod_{i=1}^n {}_{N_i}C_{y_i} P_i^{y_i} (1 - P_i)^{N_i - y_i}$$

- $f(y_1, y_2, \dots, y_n | \beta_0, \beta_1)$  をパラメタ  $\beta_0, \beta_1$  の関数  $L(\beta_0, \beta_1) \cdots$  尤度



# 最尤推定法によるパラメタ推定

## ロジスティック回帰モデル

- 対数尤度関数

$$\begin{aligned} \log L(\beta_0, \beta_1) = & \sum_{i=1}^n \log N_i C_{y_i} + \sum_{i=1}^n (y_i \log P_i) \\ & + \sum_{i=1}^n \{(N_i - y_i) \log(1 - P_i)\} \end{aligned}$$

# 最尤推定法によるパラメタ推定

## 正規分布モデルと最小二乗法

- 回帰モデル  $y = f(\mathbf{x}|\boldsymbol{\beta})$  を当てはめるとき、  
 $y$  が平均  $f(\mathbf{x}|\boldsymbol{\beta})$ 、分散  $\sigma^2$  の正規分布にしたがう

$$g(y|\mathbf{x}, \boldsymbol{\beta}) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[ -\frac{\{y - f(\mathbf{x}|\boldsymbol{\beta})\}^2}{2\sigma^2} \right]$$

- 最尤推定法によるパラメタの推定値と  
最小二乗法によるパラメタの推定値は一致する

# 最尤推定法によるパラメタ推定

## 正規分布モデルと最小二乗法

$$\begin{aligned} L(\boldsymbol{\beta}) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[ -\frac{\{y_i - f(\mathbf{x}_i|\boldsymbol{\beta})\}^2}{2\sigma^2} \right] \\ &= \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left[ -\frac{\sum_{i=1}^n \{y_i - f(\mathbf{x}_i|\boldsymbol{\beta})\}^2}{2\sigma^2} \right] \\ J &= \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n \{y_i - f(\mathbf{x}_i|\boldsymbol{\beta})\}^2 \end{aligned}$$

# 最尤推定法によるパラメタ推定

## モデル選択

- パラメタ数が多いほど良いモデルという訳ではない
- 予測精度の高いモデル, 本質を捉えたモデル
- 様々なモデル選択基準
- 赤池の情報量基準 (AIC)

$$AIC(k) = -2 \text{最大対数尤度} + 2k$$

$k$ はパラメタ数

AICが小さいほど良いモデル

## 最尤推定法によるパラメタ推定

- コンピュータを内蔵した機器同士がネットワークにより接続され，自律的に連係動作することにより，人の生活を支援する技術と環境  
… ユビキタスネットワーク，  
IoT (Internet of Things)
- 多様で大量のデータ
- 役に立つ変数はほんの一部
- モデル選択，正則化