

平成24年度 東京大学理学部情報科学科

月曜2限10:30~12:00

理7-214

知識処理論

2012年4月16日(月)

井元清哉

東京大学医科学研究所

ヒトゲノム解析センター

DNA情報解析分野


<http://bonsai.hgc.jp/~imoto>

imoto@ims.u-tokyo.ac.jp

- 回帰モデル
- 正規分布
- 最小二乗法
- 尤度
- 最尤法
- 正規方程式
- ベクトルでの微分
- 数値最適化: ニュートン・ラフソン法

- 正則化法
- 正則化パラメータ
- ベイズアプローチ
- スパース学習

回帰分析



回帰モデル (加法ノイズ)

データ: $(x_1, y_1), \dots, (x_n, y_n)$; n 個の観測値

モデル:

$$y_i = m(x_i) + e_i \quad i = 1, \dots, n$$

[観測値]=[シグナル]+[ノイズ] に分解

線形回帰モデル

データ: $(x_1, y_1), \dots, (x_n, y_n)$; n 個の観測値

シグナル:

$$m(x_i) = E[Y_i | x_i] = a_0 + a_1 x_i$$

線形回帰モデル:


$$y_i = \underline{a_0 + a_1 x_i} + e_i \quad E[e_i] = 0, V[e_i] = \sigma^2$$

x の線形式

a_0, a_1 : パラメータ

正規線形回帰モデル:

$e_i \sim N(0, \sigma^2)$: 正規分布 平均0, 分散 σ^2



回帰モデル (一般化)

データ: $(x_1, y_1), \dots, (x_n, y_n)$; n 個の観測値

モデル:

確率的成分: $f(y | x; \theta)$

系統的成分: $E[Y_i | x_i] = m(x_i)$

例

データ: $(x_1, y_1), \dots, (x_n, y_n)$; n 個の観測値

モデル:

確率的成分:

$$f(y_i | x_i; \theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(y_i - \mu_i)^2}{2\sigma^2}\right\}$$

系統的成分:

$$\mu_i = E[Y_i | x_i] = \beta_0 + \beta_1 x_i$$

正規線形回帰モデル:

$$f(y_i | x_i; \theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(y_i - \beta_0 - \beta_1 x_i)^2}{2\sigma^2}\right\}$$

モデルの当てはめ: 最尤法

データ: $(x_1, y_1), \dots, (x_n, y_n)$; n 個の観測値

正規線形回帰モデル:

$$f(y_i | x_i; \theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(y_i - \beta_0 - \beta_1 x_i)^2}{2\sigma^2}\right\}$$

パラメータ: $\beta_0, \beta_1, \sigma^2$


尤度: $L(\beta_0, \beta_1, \sigma^2) = \prod_{i=1}^n f(y_i | x_i; \beta_0, \beta_1, \sigma^2)$

y_1, \dots, y_n は互いに独立


最尤法

データ: x_1, \dots, x_n

(例えば, 東京大学の男子学生の身長)



ヒストグラム



確率分布モデル

データ x_1, \dots, x_n は次の確率密度関数を持つ分布から得られたと仮定する


$$f(x|\theta),$$

ただし, θ はパラメータ.

例えば, 正規分布

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

正規分布の当てはめ



どれがより良くデータに当てはまっているか？


尤度

データ: x_1, \dots, x_n


モデル: $f(x | \theta)$

$$\text{尤度関数: } L(\theta) = \prod_{i=1}^n f(x_i | \theta)$$

赤のモデルは？



黒のモデルは？



もっともデータに良く当てはまる パラメータ値は？

最尤推定量 $\hat{\theta}$

$$\begin{aligned}\hat{\theta} &= \arg \max_{\theta} L(\theta) \\ &= \arg \max_{\theta} \prod_{i=1}^n f(x_i | \theta)\end{aligned}$$

通常は対数尤度関数の最大化

$$l(\theta) = \log L(\theta) = \sum_{i=1}^n \log f(x_i | \theta)$$

正規モデルの最尤推定量

モデル: $f(x_i | \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(x_i - \mu)^2}{2\sigma^2}\right\}$

対数尤度関数:

$$l(\mu, \sigma^2) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

最尤推定量:

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i, \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu})^2$$

正規線形モデルの最尤推定

データ: $(x_1, y_1), \dots, (x_n, y_n)$; n 個の観測値

正規線形回帰モデル:

$$f(y_i | x_i; \theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(y_i - \beta_0 - \beta_1 x_i)^2}{2\sigma^2}\right\}$$

パラメータ: $\beta_0, \beta_1, \sigma^2$

尤度: $L(\beta_0, \beta_1, \sigma^2) = \prod_{i=1}^n f(y_i | x_i; \beta_0, \beta_1, \sigma^2)$

正規線形モデルの最尤推定は 最小2乗法と等価である

$$\begin{aligned}
 l(\beta_0, \beta_1, \sigma^2) &= \log L(\beta_0, \beta_1, \sigma^2) \\
 &= \sum_{i=1}^n \log f(y_i | x_i; \beta_0, \beta_1, \sigma^2) \\
 &= \sum_{i=1}^n \log \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(y_i - \beta_0 - \beta_1 x_i)^2}{2\sigma^2}\right\} \\
 &= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \\
 &= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \underline{S(\beta_0, \beta_1)}
 \end{aligned}$$

β_0, β_1 に対する $l(\beta_0, \beta_1, \sigma^2)$ の最大化 $\Leftrightarrow S(\beta_0, \beta_1)$ の最小化

最小2乗法

データ: $(x_1, y_1), \dots, (x_n, y_n)$; n 個の観測値

線形回帰モデル:

$$y_i = \beta_0 + \beta_1 x_i + e_i \quad E[e_i] = 0, \text{Var}[e_i] = \sigma^2$$

x の線形式

β_0, β_1 ; パラメータ

パラメータ推定:

$$S(\beta_0, \beta_1) = \sum_{i=1}^n \{y_i - (\beta_0 + \beta_1 x_i)\}^2$$

を最小化

正規線形モデルに対する

最尤推定量(=最小2乗推定量)

$$l(\beta_0, \beta_1, \sigma^2) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2$$


$$= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})$$


ただし

$$\mathbf{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix}$$

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

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

最尤法: 回帰分析



多変量データ

データ: $(x_{11}, x_{12}, \dots, x_{1p}, y_1),$
 $(x_{21}, x_{22}, \dots, x_{2p}, y_2),$
 $\dots\dots\dots,$
 $(x_{n1}, x_{n2}, \dots, x_{np}, y_n)$

線形重回帰モデル:

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

正規線形重回帰モデルの最尤推定

線形重回帰モデルの尤度も単回帰と同様

$$\begin{aligned} l(\boldsymbol{\beta}, \sigma^2) &= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \\ &= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \end{aligned}$$

とかける

ベクトルでの微分

定義 $\boldsymbol{\theta} = (\theta_1, \dots, \theta_p)^T$ としたとき

$$\frac{\partial f(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \left(\frac{\partial f(\boldsymbol{\theta})}{\partial \theta_1}, \dots, \frac{\partial f(\boldsymbol{\theta})}{\partial \theta_p} \right)^T$$

公式

$\mathbf{a} = (a_1, \dots, a_p)^T$, $\mathbf{x} = (x_1, \dots, x_p)^T$, $\mathbf{B} = (b_{ij})_{p \times p}$ のとき

$$(I) \frac{\partial \mathbf{a}^T \mathbf{x}}{\partial \mathbf{x}} = \mathbf{a}$$

$$(II) \frac{\partial \mathbf{x}^T \mathbf{x}}{\partial \mathbf{x}} = 2\mathbf{x}, \quad \frac{\partial \mathbf{x}^T \mathbf{B}\mathbf{x}}{\partial \mathbf{x}} = (\mathbf{B} + \mathbf{B}^T)\mathbf{x}, \quad \frac{\partial \mathbf{x}^T \mathbf{B}\mathbf{y}}{\partial \mathbf{x}} = \mathbf{B}\mathbf{y}$$

$$\begin{aligned}
 l(\boldsymbol{\beta}, \sigma^2) &= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \\
 &= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})
 \end{aligned}$$


$$\left. \frac{\partial l(\boldsymbol{\beta}, \sigma^2)}{\partial \boldsymbol{\beta}} \right|_{\boldsymbol{\beta}=\hat{\boldsymbol{\beta}}} = -\frac{1}{2\sigma^2} (2\mathbf{X}^T \mathbf{X} \hat{\boldsymbol{\beta}} - 2\mathbf{X}^T \mathbf{y}) = 0$$

$$\Rightarrow \mathbf{X}^T \mathbf{X} \hat{\boldsymbol{\beta}} = \mathbf{X}^T \mathbf{y}$$

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

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

幾何的考察



X の列ベクトルは一次独立

説明変数間の相関、データ数

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

$$\mathbf{X} = (\mathbf{x}_{(0)}, \dots, \mathbf{x}_{(p)}) : n \times (p+1) \text{ 行列}$$

$$\mathbf{X}^T \mathbf{X} : (p+1) \times (p+1) \text{ 行列}$$

$n < p+1$ であつたり、独立な説明変数でない場合

$$\text{rank}(\mathbf{X}^T \mathbf{X}) < p+1$$

$$\hat{\mathbf{y}} = \mathbf{X} \hat{\boldsymbol{\beta}} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \text{ の } (\mathbf{X}^T \mathbf{X})^{-1} \text{ が存在しない}$$