

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23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

正則化法1

β の推定については、対数尤度

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

の最大化は、残差2乗和

$$S(\beta) = (y - X\beta)^T (y - X\beta)$$

の最小化と同値

$$\hat{\beta} = \min_{\beta} S(\beta) \quad \rightarrow \quad \hat{\beta} = \underline{(X^T X)^{-1} X^T y}$$

正則化法2

残差2乗和を修正する


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

$\hat{\boldsymbol{\beta}}_p = \min_{\boldsymbol{\beta}} S_\lambda(\boldsymbol{\beta})$ を求めてみましょう

正則化法3

$\hat{\boldsymbol{\beta}}_p = \min_{\boldsymbol{\beta}} S_\lambda(\boldsymbol{\beta})$ は次式で与えられる:

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

$\mathbf{X}^T \mathbf{X}$ の対角成分に λ を足している  正則化

λ の値を適切に決める必要がある。それは後日の講義で。

$S_\lambda(\boldsymbol{\beta})$ は罰則付き残差2乗和 (Penalized sum of squared residuals) と呼ばれる。

$\hat{\boldsymbol{\beta}}_p$ は Ridge estimator と呼ばれる。

正則化法と最尤法

$$\begin{aligned}
 S_\lambda(\boldsymbol{\beta}) &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) + \lambda \boldsymbol{\beta}^T \boldsymbol{\beta} \\
 &\Rightarrow -\frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) - \frac{\lambda}{2} \boldsymbol{\beta}^T \boldsymbol{\beta} \\
 &\Rightarrow \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})\right\} \cdot \left(\frac{\lambda}{2\pi}\right)^{(p+1)/2} \exp\left(-\frac{\lambda}{2} \boldsymbol{\beta}^T \boldsymbol{\beta}\right) \\
 &= \underbrace{L(\boldsymbol{\beta}, \sigma^2)} \cdot \underbrace{p(\boldsymbol{\beta})}
 \end{aligned}$$

尤度 この項の解釈は？

 ベイズ統計学から解釈ができる

ベイズ統計学

データ: $x_1, x_2, \dots, x_n \sim X$

統計モデル: $f(x|\boldsymbol{\theta})$

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

ベイズ統計学における推測は $\boldsymbol{\theta}$ の事後分布

$$p(\boldsymbol{\theta} | \mathbf{x}) = \frac{L(\boldsymbol{\theta})p(\boldsymbol{\theta})}{p(\mathbf{x})}$$

によって行われる。

ベイズの定理

事象 A, B に対して $\Pr(A | B) = \frac{\Pr(B | A)\Pr(A)}{\Pr(B)}$ が成り立つ。

事象 A_1, A_2, \dots, A_m が $A_i \cap A_j = \phi, A_1 \cup A_2 \cup \dots \cup A_m = \Omega$ を満たすとき

$$\Pr(B) = \Pr(B | A_1)\Pr(A_1) + \Pr(B | A_2)\Pr(A_2) + \dots + \Pr(B | A_m)\Pr(A_m)$$

が成り立つ。

これらを合わせると

$$\Pr(A_i | B) = \frac{\Pr(B | A_i)\Pr(A_i)}{\sum_{j=1}^m \Pr(B | A_j)\Pr(A_j)}$$

が成り立つ。これはベイズの定理と呼ばれる。

結果から原因を探る

確率変数: X, Y

X は結果 Y の原因である:

$$\Pr(Y | X)$$

は原因が与えられた下での結果が起こる確率を表す。

(例) X : 夜更かし, Y : 朝寝坊

(例) X : アスベスト, Y : 中皮腫

(例) X : SNP, Y : 癌



要するに、 $\Pr(Y | X)$ は普通に想像されうる確率。

今、 X と Y を入れ替えた確率 $\Pr(X | Y)$ を考える。

この確率は、**結果が与えられた下での原因の起こる確率**である。

複数の原因 X_1, X_2, \dots, X_m が想定される状況を考える: このとき、

$$\Pr(X_1 | Y), \Pr(X_2 | Y), \dots, \Pr(X_m | Y)$$

を計算し、その最大値 $\max_X \Pr(X | Y)$ を与える X を探す。

**結果 Y が起こったという観測データに基づく
原因 X を特定するための科学的的方法論を与えている。**

θ の事後分布からの推測

$$p(\theta | x) = \frac{L(\theta)p(\theta)}{p(x)} = \frac{\text{尤度} \times \theta \text{の事前分布}}{\text{規格化定数}}$$

パラメータ θ の推定

$$\hat{\theta}_{\text{MAP}} = \operatorname{argmax}_{\theta} p(\theta | x) \quad \text{事後確率最大化 (Maximum a posteriori)}$$

$$\hat{\theta}_{\text{Bayes}} = E_{p(\theta | x)}[\theta] \quad \text{期待値}$$

新しいデータ z の分布 $p(z | x)$ (予測分布)

$$\text{MAP推定では } p(z | x) = p(z | \hat{\theta}_{\text{MAP}})$$

$$\text{ベイズ推定では } p(z | x) = \int p(z | \theta)p(\theta | x)d\theta$$

知識のアップデート

パラメータ θ に
関する事前の知識

パラメータ θ の
事前分布

$$p(\theta)$$



データ x の情報を
加味したパラメータ θ の分布

パラメータ θ の
事前分布

$$p(\theta | x)$$

得られたデータ x の
情報を θ の空間で表現

$$L(\theta)$$

$$p(\theta | x) = \frac{L(\theta)p(\theta)}{p(x)}$$

事前分布、尤度、事後分布：例

