

<https://goo.gl/tYmyZL>

KYOTO UNIVERSITY

統計的モデリング基礎⑤ ～最尤推定（続き）～

鹿島久嗣
(情報学科 計算機科学コース)

DEPARTMENT OF INTELLIGENCE SCIENCE
AND TECHNOLOGY

中間テスト：

6/7(水) 4限 総合研究8号館NSホール

- 講義内で行います
- 範囲は第1～7回
- 持ち込み等なし

マーケティング分野への応用を対象とした参考書



マーケティングの統計モデル

出版社：朝倉出版
発刊年月：2015.8
ISBN：4254128533
A5判；192ページ

マーケティングを題材としながら、基本的な統計的モデリングの方法が学べる

3

KYOTO UNIVERSITY

最尤推定：

データをもっともよく再現するパラメータを推定値とする

- n 個のデータ x_1, x_2, \dots, x_n から確率モデル $f(x | \theta)$ のパラメータ θ を推定したい
- n 個のデータが（互いに独立に）生成される確率（尤度）：

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

- 尤度最大になるパラメータを推定値 $\hat{\theta}$ とする

$$\hat{\theta} = \operatorname{argmax}_{\theta} \prod_{i=1}^n f(x_i | \theta) = \operatorname{argmax}_{\theta} \sum_{i=1}^n \log f(x_i | \theta)$$

実際には対数尤度で扱うことが多い

—もっともデータを生成する確率が高い（「最も尤もらしい」）

4

KYOTO UNIVERSITY

線形回帰モデルの最尤推定： 線形回帰の確率モデル

- データ： $\mathbf{x} = (x^{(1)}, x^{(2)}, \dots, x^{(n)})$ と $\mathbf{y} = (y^{(1)}, y^{(2)}, \dots, y^{(n)})$ に
線形モデル： $g(x) = \beta x + \alpha$ を当てはめる
- 最小二乗法： $\ell(\alpha, \beta) = \sum_{i=1}^n (y^{(i)} - (\beta x^{(i)} + \alpha))^2$ を最小化
- 一方、線形回帰モデルに対応する確率モデルを考えると：
 - 正規分布： $y^{(i)}$ は平均 $\beta x^{(i)} + \alpha$ 、分散 σ^2 の正規分布に従う
 - 確率密度： $f(y^{(i)} | x^{(i)}) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y^{(i)} - (\beta x^{(i)} + \alpha))^2}{2\sigma^2}\right)$
 - 「平均的に」回帰直線 $y = \beta x + \alpha$ に乗るデータを生成できる

5

KYOTO UNIVERSITY

線形回帰モデルの最尤推定： 線形回帰の確率モデルの最尤推定 = 最小二乗法

- 線形回帰モデルに対応する確率モデルを考える：
- 確率密度関数： $f(y^{(i)}) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y^{(i)} - (\beta x^{(i)} + \alpha))^2}{2\sigma^2}\right)$
- 対数尤度： $L(\alpha, \beta) = \sum_{i=1}^n \log f(y^{(i)} | x^{(i)})$
$$= -\frac{1}{2\sigma^2} \sum_{i=1}^n (y^{(i)} - (\beta x^{(i)} + \alpha))^2 + \text{const.}$$
- 対数尤度を α, β について最大化すること（最尤推定）
= 二乗誤差を α, β について最小化すること（最小二乗法）

6

KYOTO UNIVERSITY

線形回帰モデルの最尤推定： 分散の最尤推定量

■ 確率密度関数： $f(y^{(i)}) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y^{(i)} - (\beta x^{(i)} + \alpha))^2}{2\sigma^2}\right)$

- 分散については、対数尤度：

$$L(\sigma^2) = \frac{n}{2} \log \frac{1}{\sigma^2} - \frac{1}{2\sigma^2} \sum_{i=1}^n (y^{(i)} - (\beta x^{(i)} + \alpha))^2 + \text{const.}$$

- $L(\sigma^2)$ を最大化する最尤推定量は：

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

※ 以上の議論は重回帰モデルの場合も同様

7

KYOTO UNIVERSITY

最尤推定の利点： モデリングの自動化

- 最尤推定の利点：確率モデルの形（データの生成プロセスの仮定）を決めればモデルパラメータが自動的に決まる
- ただし、最大化問題を解く必要がある
 - 離散分布、ポアソン分布、正規分布などは解析的に解が求まる
 - 線形回帰（正規分布でノイズが載る）は連立方程式（いちおう解析的な解）
 - 多くのモデルでは、最適化問題を数値的に解く必要がある

8

KYOTO UNIVERSITY

最尤推定量の性質： 一貫性

- モデルパラメータ θ の推定量として $\hat{\theta}$ を得た（例えば最尤推定で）
- 推定量の良さはどのように評価するか
 - 不偏性 $E_{\theta}[\hat{\theta}] = \theta$ ：推定量の期待値が真の値に一致する
 - 分散の最尤推定量は不偏性をもたない
 - 一貫性：標本サイズを大きくしていくと真の値に一致する：

$$\hat{\theta} \xrightarrow{n \rightarrow \infty} \theta$$

- 最尤推定は、適当な条件のもと一貫性をもつ

9

KYOTO UNIVERSITY

漸近正規性： 最尤推定は漸近正規性をもつ

- 最尤推定量の分布は $n \rightarrow \infty$ で、真のパラメータ θ を平均とする正規分布に従う
- もう少し厳密にいうと：
 - $\sqrt{n}(\hat{\theta} - \theta)$ の分布が平均 θ 、分散 $I(\theta)^{-1}$ の正規分布に近づく
 - $I(\theta)$ はフィッシャー情報量：

$$\begin{aligned} I(\theta) &= -E_{\theta} \left[\frac{\partial^2}{\partial \theta^2} \log f(x|\theta) \right] \\ &= - \int \left(\frac{\partial^2}{\partial \theta^2} \log f(x|\theta) \right) f(x|\theta) dx \end{aligned}$$

- $n \rightarrow \infty$ で $\hat{\theta} \rightarrow \theta$

10

KYOTO UNIVERSITY

ポアソン回帰： 非負整数の回帰モデル

- 例えば、ある機械の各日の故障件数をモデル化したい
 - 曜日や気温などに依存して平均的な故障件数が変わるとする
- 独立変数に依存する回数のモデル：ポアソン回帰

$$P(Y = k | \mathbf{x}, \boldsymbol{\beta}) = \frac{(\boldsymbol{\beta}^\top \mathbf{x})^k}{k!} \exp(-\boldsymbol{\beta}^\top \mathbf{x})$$

–ポアソン分布の平均が線形モデルで表される

- ポアソン分布： $P(Y = k | \lambda) = \frac{\lambda^k}{k!} \exp(-\lambda)$
 - 重回帰モデル： $\lambda = \boldsymbol{\beta}^\top \mathbf{x}$
- } 組み合わせる

ポアソン回帰の最尤推定： 解析解は得られなさそう

- 独立変数： $(\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(n)})$ # n 日分の測定
- 従属変数： $(y^{(1)}, y^{(2)}, \dots, y^{(n)})$ # n 日分の故障数
- 対数尤度：

$$\begin{aligned} L(\boldsymbol{\beta}) &= \sum_{i=1}^n \log \frac{(\boldsymbol{\beta}^\top \mathbf{x}^{(i)})^{y^{(i)}}}{y^{(i)!}} \exp(-\boldsymbol{\beta}^\top \mathbf{x}^{(i)}) \\ &= \sum_{i=1}^n y^{(i)} \log(\boldsymbol{\beta}^\top \mathbf{x}^{(i)}) - \sum_{i=1}^n \boldsymbol{\beta}^\top \mathbf{x}^{(i)} + \text{const.} \end{aligned}$$

- これを最大化する $\boldsymbol{\beta}$ を求めたいが、解析解は得られない

判別問題： ダミー変数を従属変数とする

- データ (n 組の独立変数と従属変数)
 - 独立変数： $(\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(n)})$
 - (ダミー) 従属変数： $(y^{(1)}, y^{(2)}, \dots, y^{(n)}), y^{(i)} \in \{+1, -1\}$


以降、表記上の利便性からダミー従属変数を
 $\{0, 1\}$ でなく $\{+1, -1\}$ と表記する
(本質的な違いはナシ)

ロジスティック回帰： ダミー変数を従属変数とするモデル

- 以前、重回帰モデルでダミー変数を従属変数とすると、厳密には少しおかしいという話だった → もっとちゃんと扱いたい
 - 重回帰モデル $y = \boldsymbol{\beta}^T \mathbf{x}$ の従属変数の値域は実数全体
- 従属変数の値域が $\{-1, +1\}$ もしくは、 $(0, 1)$ ($Y = +1$ となる確率) となるようにしたい
- ロジスティック回帰モデル：

$$P(Y = 1 | \mathbf{x}, \mathbf{w}) = \frac{1}{1 + \exp(-\mathbf{w}^T \mathbf{x})} = \sigma(\mathbf{w}^T \mathbf{x})$$


- σ : ロジスティック関数 ($\sigma: \mathbb{R} \rightarrow (0, 1)$)



ロジスティック回帰モデルの対数尤度：
凸関数なので大局解が得られるが解析解はない

▪ 対数尤度： $L(\mathbf{w}) = -\sum_{i=1}^n \log(1 + \exp(-y^{(i)} \mathbf{w}^\top \mathbf{x}^{(i)}))$
 $\left(= \sum_{i=1}^n \delta(y^{(i)} = 1) \log \frac{1}{1 + \exp(-\mathbf{w}^\top \mathbf{x}^{(i)})} + \delta(y^{(i)} = -1) \log \left(1 - \frac{1}{1 + \exp(-\mathbf{w}^\top \mathbf{x}^{(i)})} \right) \right)$

- $L(\mathbf{w})$ は凸関数：
 - 大局解が得られる
 - 解析解はない



ロジスティック回帰のパラメータ推定：
非線形最適化

- 最尤推定の目的関数（最大化）：

$$L(\mathbf{w}) = -\sum_{i=1}^n \log(1 + \exp(-y^{(i)} \mathbf{w}^\top \mathbf{x}^{(i)}))$$

- 解析解は得られないが、凸関数（2階微分が ≤ 0 ）
 ▪ 数値的な最適化手法を使う
 - パラメータの更新をくりかえす： $\mathbf{w}^{\text{NEW}} \leftarrow \mathbf{w} + \mathbf{d}$



パラメータ更新：

目的関数をもっとも改善する更新を行う

- 更新 $\mathbf{w}^{\text{NEW}} \leftarrow \mathbf{w} + \mathbf{d}$ によって目的関数の値が変化する：

$$L_{\mathbf{w}}(\mathbf{d}) = - \sum_{i=1}^n \ln(1 + \exp(-y^{(i)}(\mathbf{w} + \mathbf{d})^T \mathbf{x}^{(i)}))$$

- $L_{\mathbf{w}}(\mathbf{d})$ を最大化する更新分 \mathbf{d}^* を見つけよ：

$$-\mathbf{d}^* = \operatorname{argmin}_{\mathbf{d}} L_{\mathbf{w}}(\mathbf{d})$$

17

KYOTO UNIVERSITY

最良のパラメータ更新：

目的関数をテイラー展開で近似

- 目的関数のテイラー展開：


$$L_{\mathbf{w}}(\mathbf{d}) = L(\mathbf{w}) + \mathbf{d}^T \nabla L(\mathbf{w}) + \frac{1}{2} \mathbf{d}^T \mathbf{H}(\mathbf{w}) \mathbf{d} + O(\mathbf{d}^3)$$

3次以上の項

$$\text{-勾配：} \nabla L(\mathbf{w}) = \left(\frac{\partial L(\mathbf{w})}{\partial w_1}, \frac{\partial L(\mathbf{w})}{\partial w_2}, \dots, \frac{\partial L(\mathbf{w})}{\partial w_D} \right)^T$$

- 目的関数が最も急な方向

$$\text{-ヘッセ行列：} [H(\mathbf{w})]_{i,j} = \frac{\partial^2 L(\mathbf{w})}{\partial w_i \partial w_j}$$



18

KYOTO UNIVERSITY

ニュートン法： 2次近似を最適化する

- テイラー展開で3次以降の項を無視する：

3次以上の項

$$L_{\mathbf{w}}(\mathbf{d}) \approx L(\mathbf{w}) + \mathbf{d}^T \nabla L(\mathbf{w}) + \frac{1}{2} \mathbf{d}^T \mathbf{H}(\mathbf{w}) \mathbf{d} + o(\mathbf{d}^3)$$

- 最大化するために \mathbf{d} で微分： $\frac{\partial L_{\mathbf{w}}(\mathbf{d})}{\partial \mathbf{d}} \approx \nabla L(\mathbf{w}) + \mathbf{H}(\mathbf{w}) \mathbf{d}$

- これを $= \mathbf{0}$ とおいて解くと： $\mathbf{d} = -\mathbf{H}(\mathbf{w})^{-1} \nabla L(\mathbf{w})$

実際には連立方程式を解く

- ニュートン法：

$$\mathbf{w}^{\text{NEW}} \leftarrow \mathbf{w} - \mathbf{H}(\mathbf{w})^{-1} \nabla L(\mathbf{w})$$

$$\mathbf{w} \xrightarrow{-\mathbf{H}(\mathbf{w})^{-1} \nabla L(\mathbf{w})} \mathbf{w} - \mathbf{H}(\mathbf{w})^{-1} \nabla L(\mathbf{w})$$

線形探索付きニュートン法： 近似は必ずしも正しくないので線形探索と組み合わせる

- ニュートン法の更新 $\mathbf{w}^{\text{NEW}} \leftarrow \mathbf{w} - \mathbf{H}(\mathbf{w})^{-1} \nabla L(\mathbf{w})$ は2次近似が正しいことを仮定している：

$$L_{\mathbf{w}}(\mathbf{d}) \approx L(\mathbf{w}) + \mathbf{d}^T \nabla L(\mathbf{w}) + \frac{1}{2} \mathbf{d}^T \mathbf{H}(\mathbf{w}) \mathbf{d}$$

– 実際には正しくない

- そこで更新の向き $\mathbf{H}(\mathbf{w})^{-1} \nabla L(\mathbf{w})$ のみを採用して：

$$\mathbf{w}^{\text{NEW}} \leftarrow \mathbf{w} - \eta \mathbf{H}(\mathbf{w})^{-1} \nabla L(\mathbf{w})$$

- 学習率 $\eta > 0$ の決定法：

– 適当にステップ数とともに適当に減衰

適当な初期値から始めて、目的関数が改善しない間は η を半分にしていく

– 線形探索： $\eta^* = \operatorname{argmax}_{\eta} L(\mathbf{w} - \eta \mathbf{H}(\mathbf{w})^{-1} \nabla L(\mathbf{w}))$

最急勾配法 :

ヘッセ行列を使わずシンプルで軽い更新

- ヘッセ行列の逆行列（もしくは連立方程式を解く）は高コスト :

– ニュートン法の更新 : $\mathbf{w}^{\text{NEW}} \leftarrow \mathbf{w} - \eta \mathbf{H}(\mathbf{w})^{-1} \nabla L(\mathbf{w})$

- 最急勾配法 :

– ヘッセ行列の逆行列 $\mathbf{H}(\mathbf{w})^{-1}$ を単位行列 \mathbf{I} で置き換え :

$$\mathbf{w}^{\text{NEW}} \leftarrow \mathbf{w} - \eta \nabla L(\mathbf{w})$$

勾配

- $\nabla L(\mathbf{w})$ は最も急な（目的関数が最も変化する）向き
- 学習率 η は線形探索で求める :



ロジスティック回帰の場合の勾配 :

比較的簡単に計算可能

- 対数尤度 : $L(\mathbf{w}) = -\sum_{i=1}^n \ln(1 + \exp(-y^{(i)} \mathbf{w}^\top \mathbf{x}^{(i)}))$

$$\frac{\partial L(\mathbf{w})}{\partial \mathbf{w}} = -\sum_{i=1}^n \frac{1}{1 + \exp(-y^{(i)} \mathbf{w}^\top \mathbf{x}^{(i)})} \frac{\partial (1 + \exp(-y^{(i)} \mathbf{w}^\top \mathbf{x}^{(i)}))}{\partial \mathbf{w}}$$

$$= \sum_{i=1}^n \frac{1}{1 + \exp(-y^{(i)} \mathbf{w}^\top \mathbf{x}^{(i)})} \exp(-y^{(i)} \mathbf{w}^\top \mathbf{x}^{(i)}) y^{(i)} \mathbf{x}^{(i)}$$

$$= \sum_{i=1}^n (1 - f(y^{(i)} | \mathbf{x}^{(i)}, \mathbf{w})) y^{(i)} \mathbf{x}^{(i)}$$

現在のパラメータでのモデルが与える確率

確率的最適化とミニバッチ： データの部分集合を用いた効率的な推定

- 対数尤度は各データの対数尤度の和： $L(\mathbf{w}) = \sum_{i=1}^n \ell^{(i)}$

- 勾配 $\frac{\partial L(\mathbf{w})}{\partial \mathbf{w}} = \sum_{i=1}^n \frac{\partial \ell^{(i)}}{\partial \mathbf{w}}$ の計算は $O(n)$ かかる

- 勾配をデータ1個で近似： $\frac{\partial L(\mathbf{w})}{\partial \mathbf{w}} \approx n \frac{\partial \ell^{(i)}}{\partial \mathbf{w}}$

– 確率的最適化：毎回データをランダムに選ぶ

– オンライン推定も可能（時刻 t のデータの $\ell^{(i)}$ を使う）

- ミニバッチ： $1 < m < n$ 個のデータで勾配を近似：

$$\frac{\partial L(\mathbf{w})}{\partial \mathbf{w}} \approx \frac{n}{m} \sum_{j \in \text{MiniBatch}} \frac{\partial \ell^{(i)}}{\partial \mathbf{w}}$$

23

KYOTO UNIVERSITY

練習： ポアソン回帰の最尤推定

- ポアソン回帰の最尤推定

– 対数尤度：

$$L(\boldsymbol{\beta}) = \sum_{i=1}^N y^{(i)} \log(\boldsymbol{\beta}^T \mathbf{x}^{(i)}) - \sum_{i=1}^N \boldsymbol{\beta}^T \mathbf{x}^{(i)} + \text{const.}$$

– 解析解は求まらない

- 最急勾配法の更新式を求めてみる

24

KYOTO UNIVERSITY