

# 行動モデルの推定

---

早稲田大学 佐々木邦明

君は、君の行動原理が同時に普遍的な法則となることを欲することができるような行動原理だけに従って行為せよ（カント）

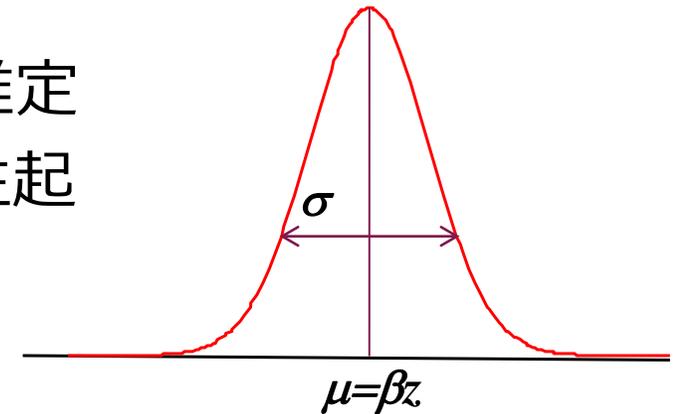
# 最尤推定

---

# 行動モデルの推定と最尤推定

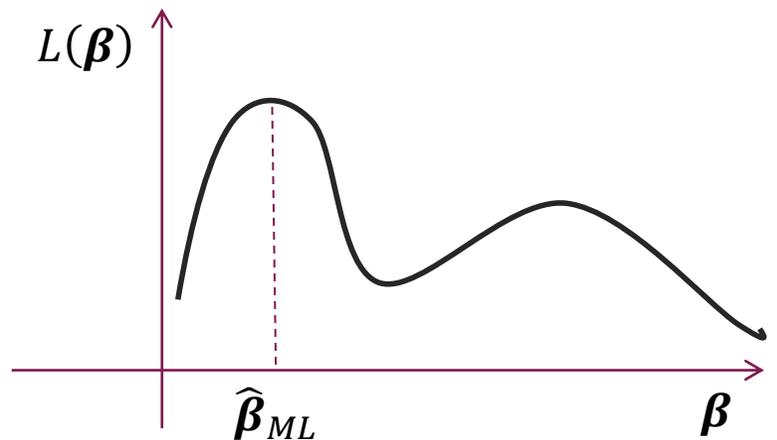
- 有限個のパラメータで記述される確率密度関数の推定
- パラメータベクトル  $\beta$ , モデル  $f$  による標本の生起確率を尤度とする

- $L(\beta) = \prod_{i=1}^n f(y_i|\beta)$



- (対数)尤度関数が最大になる  $\theta$  を最尤推定値とする

- $\hat{\beta}_{ML} = \underset{\beta}{\operatorname{argmax}} \log L(\beta)$



# 最尤推定法

- 点推定量を求める一般的な方法
- 右上の式を $\theta$ の関数とみなしたものが尤度関数
- 尤度関数を最大化する $\theta$ の値を最尤推定量とするのが最尤推定法

$$L_n(\boldsymbol{\beta}|x) = \prod_{i=1}^n f(x_i|\boldsymbol{\beta})$$

## 平均値の推定を例にすると

データ( $\mathbf{x} : 3, 5, 4$ )が得られたとき、  
平均をいくつとするのがよいか？

⇒平均がいくつの分布だったら

データ( $\mathbf{x} : 3, 5, 4$ )がもっとも得られやすいか？

# ロジットモデルの最尤推定

- $L(\mu\boldsymbol{\beta}) = \prod_{i=1}^n f(\mathbf{y}_i | \mu\boldsymbol{\beta})$

- $f(\mathbf{y}_i | \mu\boldsymbol{\beta}) = \prod_{j=1}^J \left\{ \frac{\exp(\mu\boldsymbol{\beta} \mathbf{x}_{ij})}{\sum_{j=1}^J \exp(\mu\boldsymbol{\beta} \mathbf{x}_{ij})} \right\}^{y_{ij}}$

- $V_{ij} = \mu\boldsymbol{\beta} \mathbf{x}_{ij} = \mu\beta_1 + \mu\beta_1 x_{1i} + \mu\beta_2 x_{2i} \cdots + \mu\beta_K x_{Ki}$

選ばれた選択肢の選択確率  
 $y_{ij}=1$ : if  $j$ =選択,  $y_{ij}=0$ : それ以外

$\beta$ は未知数,  $x$ は観測値

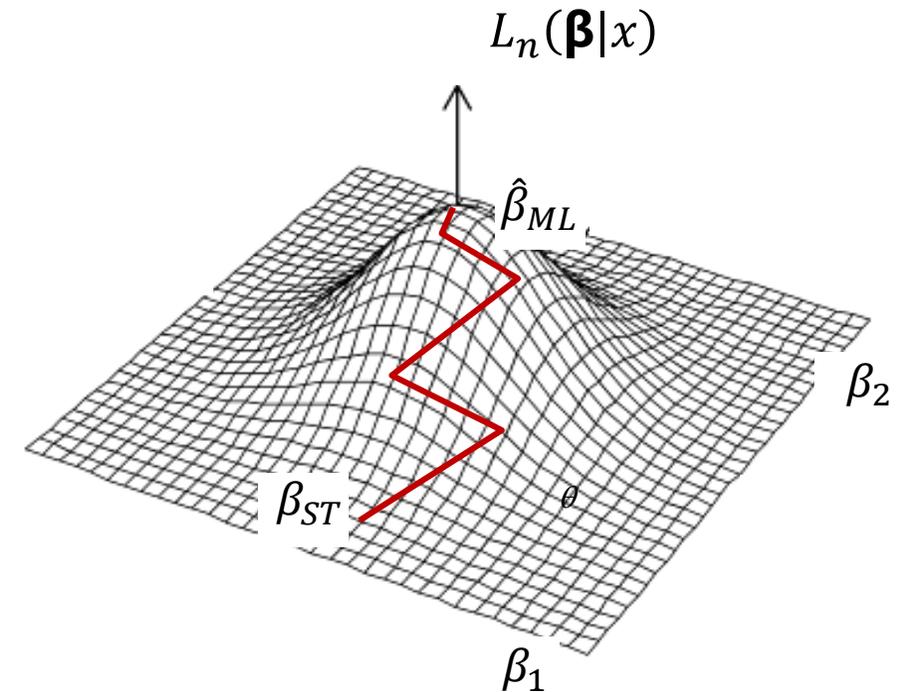
選択結果( $\mathbf{y}_i$  :  $y_1$ =車,  $y_2$ =車,  $y_3$ =鉄道,  $y_4$ =鉄道,  $y_5$ =鉄道,  $y_6$ =車, ...)が得られたとき,  $\mu\boldsymbol{\beta}$ をいくつかとすると, データへの適合がよいのか?

⇒  $\mu\boldsymbol{\beta}$ がいくつかだったらデータ( $\mathbf{y}$ )が得られやすいのか?  
 $\mu\boldsymbol{\beta}$ を色々と変えてみて一番Lが高くなる $\mu\boldsymbol{\beta}$ を探す

# 最大化アルゴリズムの考え方

周りがあまり見えない中で、近傍の情報から頂点を目指す

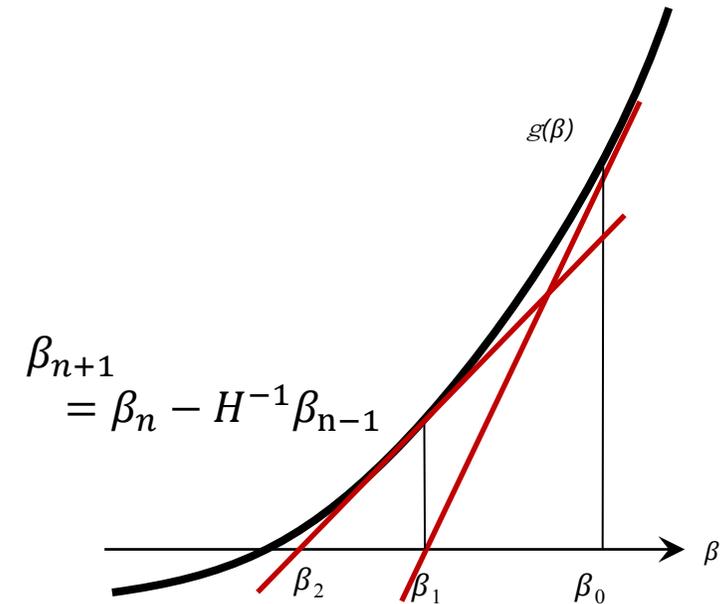
- 対数尤度関数の段階的な最大化
  - 初期値を与える
  - 初期値周りで勾配(1次微分) 等を用いて次の推定値の方向を決める
  - 初期値付近で1次微分, 2次微分を用いて適切に次の点を決めて推定値を得る
  - 収束基準(一次微分ベクトル)で判定し, 収束していない場合は, 現在の値から次の推定値に移る



# 代表的な繰り返し計算法

尤度関数を最大化 尤度関数の一階微分 = 0 を解く

- Newton-Raphson法
  - テイラー展開の1次近似を利用して進める
- 準Newton法 (BFGS, L-BFGS法)
  - ヘッセ行列を, パラメータの差分と一階微分の差分を用いて逐次近似する.
  - L-BFGSはヘッセ行列の更新式を展開して, 初期値と差分の関数  
和で表す.



H: 尤度関数の二階微分    ヘッセ行列  
g: 尤度関数の一階微分

# パラメータ推定がうまくいかない

- 収束するとは $\beta_{n+1}$ と $\beta_n$ が同じになる

- $g'$ が0になる

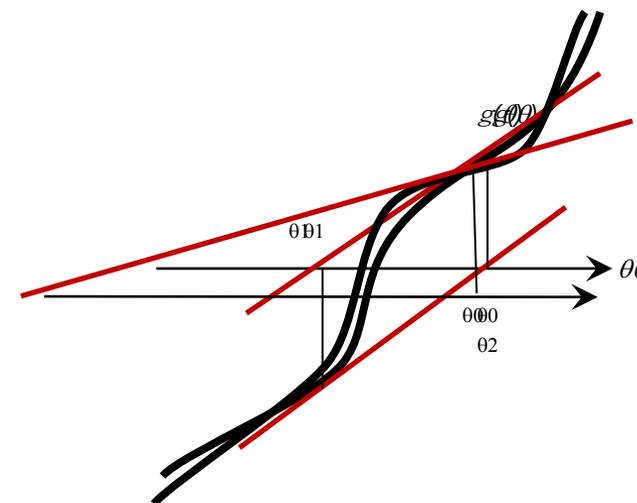
- 収束しない

- 無限に繰り返す
  - $\beta_2$ が計算不能

- 局所最適解

- 見かけ上の最大化

- $H^{-1}$ ヘッセ行列の逆行列が早々に死亡
    - 変数が完全相関
    - 変数が効用関数に影響しないモデル
- 関数の近似状況
  - 初期値の問題
- モデルに誤り
  - 意思決定者間で異なるが、選択肢間では異なる変数
  - 選択肢間では異なるが、意思決定者間で異なる変数



# 最尤推定法におけるモデル選択

- 真の確率密度関数を近似するものが含まれる必要がある
- ⇒フレキシブルなモデルを選ぶ
- 最尤推定は自由度の高さ前提
- ⇒自由度が低すぎるモデルは不適切（過適合）

$$\begin{bmatrix} \sigma_{11} & \cdots & \sigma_{1n} \\ \vdots & \ddots & \vdots \\ \sigma_{n1} & \cdots & \sigma_{nn} \end{bmatrix}$$

- 平均対数尤度の比較（KL情報量）

- 例：共分散行列を考える

- (非)制約モデル（A対称行列，B対角行列，C対角行列で分散同一）を考えるとCはBに含まれ，BはAに含まれるので，平均対数尤度 $L^*$ は必ず
- $L^*(A) \geq L^*(B) \geq L^*(C)$ になる。

$$AIC = - \sum_{i=1}^n \log f(x_i, \hat{\theta}_{ML}) + t$$

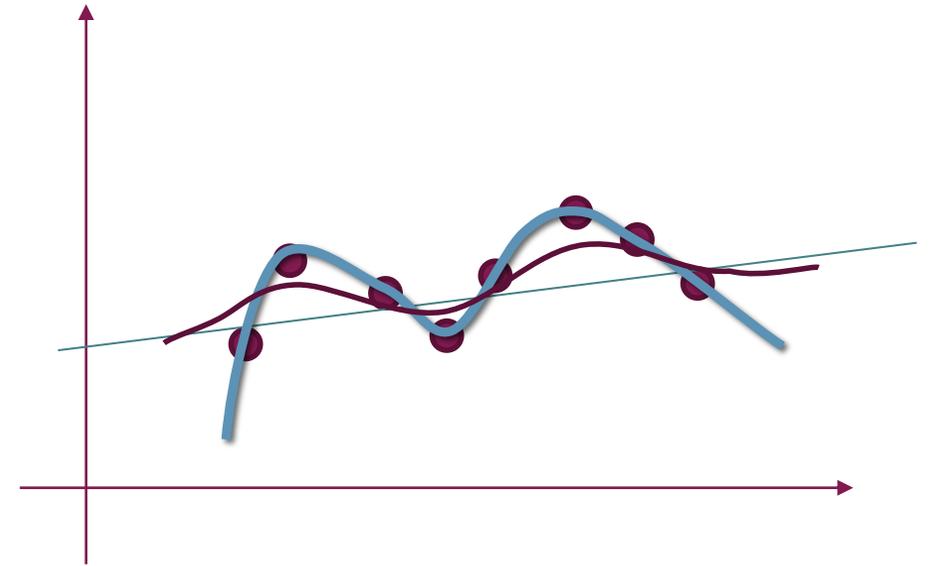
# モデル選択

---

# パラメータ推定と過学習

- 機械学習における学習
  - 判断の根拠となるための統計的なモデルを作る過程
- 機械学習の主な目的は「予測」
  - ある移動手段がどの程度選ばれそうか
  - ある個人が車を購入しそうか

## • フィットティング



- 仮説に基づく制約をモデルとして導入せず、予測精度が上がるようにモデルを自由に作る

# スパース推定と行動モデル

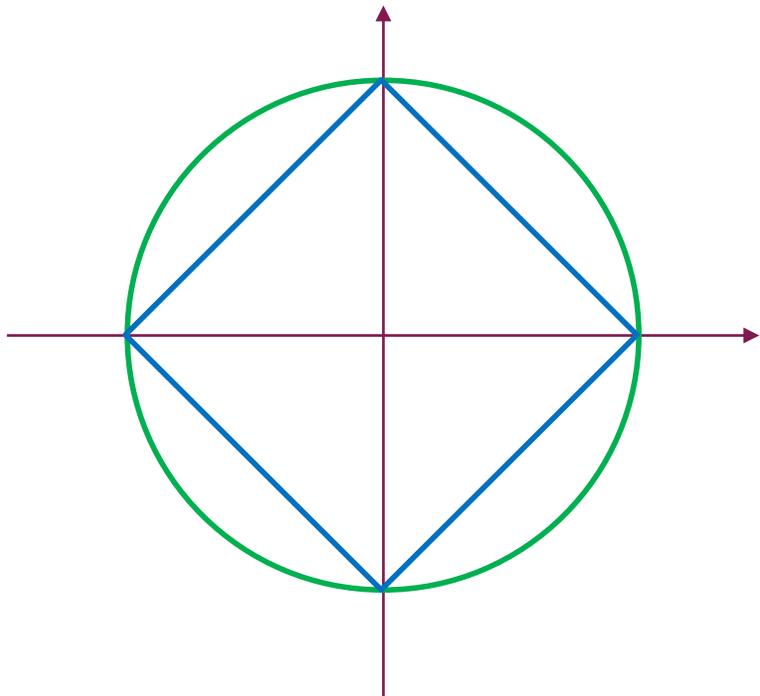
- **スパースモデリング**を用いることでデータが不足していても解析することができる
  - **スパースモデリング**を利用することにより大量のデータを使わずに済み、データ解析にかかる時間を短縮できる
  - **スパースモデリング**によって複雑なデータ構造をわかりやすく表現する  
日高他, 2017
- 
- **行動モデル**を用いることで、データが不足していても解析することができる
  - **行動モデル**を利用することにより大量のデータを使わずに済み、データ解析にかかる時間を短縮できる
  - **行動モデル**によって複雑なデータ構造をわかりやすく表現する

# 正則化によるスパース推定

- $L^2$  ノルム :  $\sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$
- $L^1$  ノルム :  $|x_1| + |x_2| + \dots + |x_n|$

- リッジ推定量

- $\min_{\beta \in \mathbb{R}^d} \|y - x\beta\|_2^2 + \lambda \|\beta\|_2^2$



P=1

P=2

- Lasso (Least Absolute Shrinkage and Selection Operator)

- $\min_{\beta \in \mathbb{R}^d} \|y - x\beta\|_2^2 + \lambda \|\beta\|_1$

# 政策分析の方法

---

## 行動モデルを用いた政策分析

- **行動モデルを推定し, そのパラメータを用いて, 変数の変化による選択の変化を見る.**
- **政策：変数の変化**
  - 例えば：**所要時間**を短縮, **駐車場の料金**を割り引く等, 政策に対応した変数が必要
- **政策評価**
  - 数え上げ法：個人の選択確率を予測して, 積み上げる  $S(j) = \frac{1}{N} \sum_{i=1}^N P_i(j)$ 
    - 最大効用の選択肢をカウント
    - 確率の平均値を求める

# シミュレーションによる政策分析

- 行動モデルを推定し, そのパラメータを用いて, 変数の変化による選択の変化を見る.
- 回遊行動の分析
  - マイクロシミュレーションを用いることで, 複雑なモデルの組み合わせを政策評価可能
  - シミュレーションなので, 複数回実施して平均的な評価を行う

Step 1

サンプルのデータ, 個人属性や発ゾーン, LOSデータなどを各段階のモデルに個人 $n$ の個人属性やLOS, 各種ダミー等といった説明変数データを代入し, 全ての選択肢ごとの選択確率 $P_{in}$ を求める. 求めた選択確率から確率分布 $F_{in}$ を作成する.

Step 2

$[0,1]$ の一様乱数 $\gamma_n$ を発生させ,  $\gamma_n$ の値が,  $F_{(i-1)n} \leq \gamma_n < F_{in}$ を満たす選択肢 $i$ を選択するものとする.