



行動モデルのパラメータ推定

早稲田大学 佐々木邦明

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 θ の下で, モデル f による標本の生起確率を尤度とする
 - $L(\theta) = \prod_{i=1}^n f(y_i|\theta)$
- (対数)尤度関数が最大になる θ を最尤推定値とする
 - $\hat{\theta}_{ML} = \underset{\theta}{\operatorname{argmax}} \log L(\theta)$



最尤推定法

- 点推定量を求める一般的な方法
- 右上の式を θ 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 θ の値を最尤推定量とするのが最尤推定法

$$L_n(\theta|y) = \prod_{i=1}^n f(y_i|\theta)$$

平均値の推定を例にすると

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

ロジットモデルの最尤推定

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

選ばれた選択肢の選択確率

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

β は未知数, x は既知のデータ

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


データ(\mathbf{y} : 馬,馬,鉄道,鉄道,鉄道,馬,鉄道, ...)が得られたとき, $\boldsymbol{\beta}$ をいくつとすると, 再現性が高いのか?

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

最大化アルゴリズムの考え方

周りが見えないうちで、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(一時微分ベクトル)で判定し, 収束していない場合は, 現在の値を初期値として2に進む



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.
- 焼きなまし法 (SANN)
 - 適当にパラメータを遷移しつつ, 関数が大きくなる遷移を選ぶ.
 - 悪化する遷移もある確率で許容し, 局所解を避ける



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 θ_{n+1} と θ_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
 - θ_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式形
 - 関数の近似状況
 - 初期値の問題
 - 推定プログラムに誤り



そもそも識別不可

- 最大値において唯一解が求まらない可能性がある（最大値となるパラメータベクトルが無数にある）
 - 意思決定者間では異なるが，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
 - 異なるモデル間でのパラメータの直接比較は無意味

例



- 効用に適切な数を足しても選択確率に変化はない
- 効用に適切な倍率をかけても選択確率に変化がない

最尤推定法の理論的性質

- 一致性
- 漸近不偏性
- 漸近有効性
- 漸近正規性

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ある必要がある
- ⇒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

- 平均対数尤度の比較 (KL情報量)

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

- 例えば, 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.

赤池の情報量基準 (AIC)

- KL情報量が適切でない理由：平均対数尤度が期待対数尤度のよい近似になっていない。

負のエントロピー

期待対数尤度

- $KL(p||\hat{p}) = E\{\log p(\mathbf{x})\} - E(\log \hat{p}(\mathbf{x}))$
- AIC(赤池の情報量基準)
 - $AIC = -\sum_{i=1}^n \log f(x_i, \hat{\theta}_{ML}) + t$
 - 負の対数尤度に補正項 t (パラメータ数) を足す

混合モデル

混合モデルの推定技法

- 混合モデル？


- $f(x_i|\theta) = \sum_{i=1}^m w_i \phi(\mu, \sigma^2)$ $L(\theta) = \prod_{i=1}^n f(x_i|\theta)$

- $\hat{\theta}_{ML} = \operatorname{argmax}_{\theta} \log L(\theta)$ *subject to* $\begin{cases} w_1, \dots, w_m \geq 0 \\ \prod_{i=1}^m w_i = 1 \end{cases}$

媒介変数


- 媒介変数を用いて尤度関数を表現できる. $w_l = \frac{\exp(\gamma_l)}{\sum_{l'=1}^L \exp(\gamma_{l'})}$

- ただし簡単に最大化できない



混合モデルの推定技法

- EM法
 - 不完全データの最適化法
 - 混合モデルは不完全データからの学習法
- 適当な初期値を定める
- 初期値に応じて媒介変数を求める (E)
- 求めた媒介変数から解を計算する (M)
- 対数尤度関数は減少せず, 局所最適解に収束する



EMアルゴリズムと潜在クラスモデル

- Eステップ (Expectation-step) : 欠測値として扱う変数の期待値の推定
 - 個人 i がクラス s に属する場合に1となる y_{is} の期待値 y_{is}^* を求める
- Mステップ (Maximization-step) : その期待値を用いたパラメータ推定
 - y_{is}^* を用いてパラメータ (π_s と $P_{i|s}(j)$) を推定する
 - 推定された π_s と $P_{i|s}(j)$ を用いて y_{is}^* を更新する
- 2つのプロセスを繰り返して最尤推定

おわりに

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 $S(j) = \frac{1}{N} \sum_{i=1}^N P_i(j)$

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 γ_n を発生させ， γ_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．