

## 集中理論談話会 #9

Bhat, C.R., Sidharthan, R.: A simulation evaluation of the maximum approximate composite marginal likelihood (MACML) estimator for mixed multinomial probit models, *Transportation Research Part B: Methodological*, Vol.45, No.7, pp.940-953, 2011.

2014/06/28

柳沼秀樹

# 1. MNP概要(MNLとの比較を通じて)

1

## 多項ロジットモデル

$$P(i) = \frac{\exp(\mu V_i)}{\sum_{j \in C} \exp(\mu V_j)}$$

- Closed-form
- 選択肢間の相関を無視(IIA)

表現力は劣るが、通常の最適化アルゴリズムでパラメータ推定が可能であり、ソースコードの開発が容易

⇒爆発的に各分野に普及

## 多項プロビットモデル

$$P(i) = \int_{\varepsilon_1 = -\infty}^{\varepsilon_i + V_i - \varepsilon_1} \cdots \int_{\varepsilon_i = -\infty}^{\infty} \cdots \int_{\varepsilon_J = -\infty}^{\varepsilon_i + V_i - \varepsilon_J} \phi(\varepsilon) d\varepsilon_J \cdots d\varepsilon_1$$
$$\phi(\varepsilon) = \frac{1}{(\sqrt{2\pi})^{J-1} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2} \varepsilon \Sigma^{-1} \varepsilon'\right)$$

- Open-form
- 選択肢間の相関を表現


表現力は高いが、選択肢数-1の多重積分が必要であり、パラメータ推定は非常に煩雑

⇒計算が困難であるため  
近年まで伸び悩む...

## 2. MNPの推定方法

2

開発当初から多重積分の計算がネックとなり、各種の数値計算アルゴリズムが提案



## (1) Maximum Approximate Composite Marginal Likelihood (MACML) estimationの提案

- ✓ Open-fromな離散選択モデル(c.f. MNP, MXL)のパラメータを **簡単かつ高速**で推定する手法を構築
- ✓ MACML推定は**2つのテクニック**により構成
  - ①多変量累積標準正規分布(MVNCD※1)の解析的近似手法
  - ②合成周辺尤度(CML※2)を用いたパラメータ推定

## (2) 各種(Mixed) Probitモデルへの適用方法の提示

- ✓ Cross-section, Panel, Spatial Correlation etc...

## (3) 数値実験による有効性の確認

- ✓ 通常の推定手法(MSL)と比較して, 計算時間は**約38倍速く** (66.09→1.96), 推定値のバイアスは**7.3ポイント**低い(9.8%→2.5%).

※1 MVNCD: Multi-Variate standard Normal Cumulative Distribution

※2 CML: Composite Marginal Likelihood

# 1. MACML推定に関する論文

4

- ① Bhat, C.R.: The maximum approximate composite marginal likelihood (MACML) estimation of multinomial probit-based unordered response choice models, *Transportation Research Part B: Methodological*, Vol.45, No.7, pp.923-939, 2011.

⇒MACMLの提案とProbitへの適用方法

- ② Bhat, C.R., Srinathran, R.: A simulation evaluation of the maximum approximate composite marginal likelihood (MACML) estimator for mixed multinomial probit models, *Transportation Research Part B: Methodological*, Vol.45, No.7, pp.940-953, 2011.


⇒数値実験によるMACMLの性能評価

- ① ~~Bhat, C.R., Sidharthan, R.: A new approach to specify and estimate normally mixed multinomial probit models, *Transportation Research Part B: Methodological*, Vol.46, No.7, pp.817-833, 2012.~~

本日の内容

- ② ⇒Skew-Normal (歪度≠0)なMNPへの適用  
Bhat, C.R., Dubey, S.: A new estimation approach to integrate psychological constructs in choice modeling, *Transportation Research Part B: Methodological*, Vol.67, pp.68-85, 2014.

⇒潜在クラスモデルへの適用



## 2.1 MVNCD (多変量累積標準正規分布) の解析的近似 ⇒ 多変量正規分布を単変量分布の積で近似

【設定1: 分布の分解】

$$\Pr(\mathbf{W} < \mathbf{w}) = \Pr(W_1 < w_1, W_2 < w_2, W_3 < w_3, \dots, W_I < w_I). \quad \mathbf{W}: \text{多変量標準正規分布}$$

同時確率を下記のように分布の積に分解

$$\Pr(\mathbf{W} < \mathbf{w}) = \underbrace{\Pr(W_1 < w_1, W_2 < w_2)}_{\text{二変量周辺分布}} \times \prod_{i=3}^I \underbrace{\Pr(W_i < w_i | W_1 < w_1, W_2 < w_2, W_3 < w_3, \dots, W_{i-1} < w_{i-1})}_{\text{単変量条件つき分布 (I>3)}}.$$

【設定2: インディケータIでの分散共分散表現】

$$\tilde{\mathbf{I}}_i = \begin{cases} 1 & W_i < w_i \\ 0 & \text{otherwise} \end{cases} \quad \begin{aligned} E(\tilde{I}_i) &= \Phi(w_i) \\ \mathbf{I} \text{の期待値を単変量累積標準正規分布 } \Phi \text{ で評価} \end{aligned}$$

$$\text{Cov}(\tilde{I}_i, \tilde{I}_i) = \text{Var}(\tilde{I}_i) = \Phi(w_i) - \Phi^2(w_i) = \Phi(w_i)[1 - \Phi(w_i)],$$

$$\text{Cov}(\tilde{I}_i, \tilde{I}_j) = E(\tilde{I}_i \tilde{I}_j) - E(\tilde{I}_i)E(\tilde{I}_j) = \Phi_2(w_i, w_j, \rho_{ij}) - \Phi(w_i)\Phi(w_j), i \neq j$$

上記を統合

$$\Pr(W_i < w_i | W_1 < w_1, W_2 < w_2, W_3 < w_3, \dots, W_{i-1} < w_{i-1}) = E(\tilde{I}_i | \tilde{I}_1 = 1, \tilde{I}_2 = 1, \tilde{I}_3 = 1, \dots, \tilde{I}_{i-1} = 1).$$

## 2. MACMLアプローチ(2)

6

### 【線形回帰モデルでの展開】

$$\Pr(W_i < w_i | W_1 < w_1, W_2 < w_2, W_3 < w_3, \dots, W_{i-1} < w_{i-1}) = \underline{E(\tilde{I}_i | \tilde{I}_1 = 1, \tilde{I}_2 = 1, \tilde{I}_3 = 1, \dots, \tilde{I}_{i-1} = 1)}.$$

$$\underline{\tilde{I}_i - E(\tilde{I}_i) = \alpha' [\tilde{\mathbf{I}}_{<i} - E(\tilde{\mathbf{I}}_{<i})] + \tilde{\eta}}, \quad \text{誤差項} \quad \times \tilde{\mathbf{I}}_{<i} = (\tilde{I}_1, \tilde{I}_2, \dots, \tilde{I}_{i-1})$$

$$\underline{\hat{\alpha}} = \Omega_{<i}^{-1} \cdot \Omega_{i,<i}, \quad \text{最小二乗係数}$$

$$\Omega_{<i} = \text{Cov}(\mathbf{I}_{<i}, \mathbf{I}_{<i}) = \begin{bmatrix} \text{Cov}(\tilde{I}_1, \tilde{I}_1) & \text{Cov}(\tilde{I}_1, \tilde{I}_2) & \text{Cov}(\tilde{I}_1, \tilde{I}_3) & \dots & \text{Cov}(\tilde{I}_1, \tilde{I}_{i-1}) \\ \text{Cov}(\tilde{I}_2, \tilde{I}_1) & \text{Cov}(\tilde{I}_2, \tilde{I}_2) & \text{Cov}(\tilde{I}_2, \tilde{I}_3) & \dots & \text{Cov}(\tilde{I}_2, \tilde{I}_{i-1}) \\ \text{Cov}(\tilde{I}_3, \tilde{I}_1) & \text{Cov}(\tilde{I}_3, \tilde{I}_2) & \text{Cov}(\tilde{I}_3, \tilde{I}_3) & \dots & \text{Cov}(\tilde{I}_3, \tilde{I}_{i-1}) \\ \vdots & & & & \\ \text{Cov}(\tilde{I}_{i-1}, \tilde{I}_1) & \text{Cov}(\tilde{I}_{i-1}, \tilde{I}_2) & \text{Cov}(\tilde{I}_{i-1}, \tilde{I}_3) & \dots & \text{Cov}(\tilde{I}_{i-1}, \tilde{I}_{i-1}) \end{bmatrix}, \quad \Omega_{i,<i} = \text{Cov}(\mathbf{I}_{<i}, \mathbf{I}_i) = \begin{bmatrix} \text{Cov}(\tilde{I}_1, \tilde{I}_1) \\ \text{Cov}(\tilde{I}_1, \tilde{I}_2) \\ \text{Cov}(\tilde{I}_1, \tilde{I}_3) \\ \vdots \\ \text{Cov}(\tilde{I}_1, \tilde{I}_{i-1}) \end{bmatrix}.$$

### 【単変量正規分布での近似】

$$\rightarrow \Pr(W_i < w_i | W_1 < w_1, W_2 < w_2, \dots, W_{i-1} < w_{i-1}) \approx \Phi(w_i) + (\Omega_{<i}^{-1} \cdot \Omega_{i,<i})' (1 - \Phi(w_1), 1 - \Phi(w_2), \dots, 1 - \Phi(w_{i-1}))'$$

多変量正規分布を選択肢数-1の単変量正規分布で表現  
⇒計算量は大幅に削減される！

### 2.2 CML(合成周辺尤度)を用いたパラメータ推定

⇒尤度関数を選択結果別の部分尤度(周辺尤度)の積で表現

【合成周辺尤度 ※パネルを想定】

全情報尤度関数(通常)

$$L_{CML}^1(\theta, \mathbf{m}) = L(\theta, \mathbf{m}) = \text{Prob}(C_1 = m_1, C_2 = m_2, C_3 = m_3, \dots, C_T = m_T).$$

合成周辺尤度関数

$$L_{CML}^2(\theta, \mathbf{m}) = \text{Prob}(C_1 = m_1) \times \text{Prob}(C_2 = m_2) \times \text{Prob}(C_3 = m_3) \times \dots \times \text{Prob}(C_T = m_T)$$

$$L_{CML}^3(\theta, \mathbf{y}) = \prod_{t=1}^{T-1} \prod_{w=t+1}^T \text{Prob}(C_t = m_t, C_w = m_w)$$

$C_t$ :  $t$ 期における個人の選択

$m_t$ :  $t$ 期における個人の選択結果

【性質】

CML推定量は一致性と漸近正規性を持つ

全情報尤度を周辺尤度に分割する事は、統計的な望ましさを保持しつつ計算量が大幅に削減される

# 3. 数値実験による性能評価

## 対象モデル

Cross-section random coefficients model (Mixed MNP)

$$U_{qi} = \beta'_q \mathbf{x}_{qi} + \varepsilon_{qi} \quad \beta_q \sim MVN(\mathbf{b}, \Omega)$$

$$L_q = \int_{\beta=-\infty}^{\infty} \left\{ \int_{\lambda=-\infty}^{\infty} \left( \prod_{i \neq m} [\Phi\{-\sqrt{2}(\beta' \mathbf{z}_{qim})\} + \lambda] \right) \phi(\lambda) d\lambda \right\} f(\beta | \mathbf{b}, \Omega) d\beta,$$

where  $\mathbf{z}_{qim} = \mathbf{x}_{qi} - \mathbf{x}_{qm}$

$q$ : 個人  
 $i$ : 選択肢  
 $\varepsilon$ : 誤差項 IIDガンベル

## 真値の設定

$$\mathbf{b} = (1.5, -1, 2, 1, -2) \quad \Omega = \begin{bmatrix} 1 & -0.50 & 0.25 & 0.75 & 0 \\ -0.50 & 1 & 0.25 & -0.50 & 0 \\ 0.25 & 0.25 & 1 & 0.33 & 0 \\ 0.75 & -0.50 & 0.33 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

5000人分の仮想データを乱数を用いて20セットの実験データを作成

# 4. 性能比較結果 MSL vs MACML(1)

## Cross-sectional random coefficients model

### 【Diagonal case】

- ・ 分散共分散行列の対角成分のみを推定
- ・ 計算時間：平均で約34倍速く、かつ速度にバラツキがない(安定的)
- ・ バイアス：平均で7.3ポイント低く、分散成分についても良好

**Table 1a**  
Evaluation of the ability to recover true parameters for the cross-sectional diagonal case.

Parameter	True value	MSL method					MACML method				
		Parameter estimates		Standard error estimates			Parameter estimates		Standard error estimates		
		Mean estimate	Absolute percentage bias (%)	Asymptotic standard error	Simulation standard error	Simulation adjusted asymptotic standard error	Mean estimate	Absolute percentage bias (%)	Asymptotic standard error	Approximation standard error	Approximation adjusted asymptotic standard error
<i>Mean values of the <math>\beta</math> vector</i>											
<i>b1</i>	1.500	1.366	9.0	0.129	0.050	0.139	1.472	1.9	0.167	0.022	0.169
<i>b2</i>	-1.000	-0.906	9.4	0.089	0.033	0.095	-0.976	2.4	0.113	0.014	0.114
<i>b3</i>	2.000	1.801	10.0	0.167	0.066	0.180	1.940	3.0	0.218	0.028	0.219
<i>b4</i>	1.000	0.906	9.4	0.089	0.034	0.095	0.977	2.3	0.114	0.014	0.114
<i>b5</i>	-2.000	-1.820	9.0	0.170	0.067	0.182	-1.960	2.0	0.220	0.028	0.222
<i>Standard deviations of the <math>\beta</math> vector</i>											
$\sigma_1$	1.000	0.885	11.5	0.111	0.038	0.117	0.958	4.2	0.135	0.017	0.137
$\sigma_2$	1.000	0.906	9.4	0.111	0.040	0.118	0.984	1.6	0.136	0.016	0.137
$\sigma_3$	1.000	0.867	13.3	0.112	0.041	0.119	0.941	5.9	0.135	0.017	0.136
$\sigma_4$	1.000	0.904	9.6	0.111	0.040	0.118	0.982	1.8	0.136	0.017	0.137
$\sigma_5$	1.000	0.927	7.3	0.117	0.041	0.124	1.002	0.2	0.140	0.016	0.141
Overall mean value across parameters	-	-	9.8%	0.121	0.045	0.129	-	2.5	0.151	0.019	0.153
Mean time		66.09					1.96				
Std. dev. of time		10.87					0.42				
% of Runs converged		100%					100%				



- 正規分布を持つOpen-formなモデル(Mixed-Probit)を対象とした新たな推定手法(MACML推定)を提案
- パネルや空間相関を考慮した改良モデルに対してもMACML推定が適用可能であることを提示
- 数値実験より高速かつ低バイアスなパラメータ推定値が得られる事を確認

### 【著者談】

*In closing, the MACML inference approach has the **potential to dramatically influence** the use of the mixed multinomial probit model in practice, and should facilitate the practical application of rich model structures for unordered-response discrete choice modeling.*