

# Discrete choice models with multiplicative error terms

Fosgerau, M., and Bierlaire, M., 2009,  
Discrete choice models with multiplicative error terms,  
Transportation Research Part.B, Vol.43, Issue.5, pp.494-505.

2009/4/21  
論文ゼミ#1  
D1 原 祐輔

# 0. 本日の目次

1. 離散選択モデル(行動モデル)の簡単な復習
  - 例を出しつつ
2. 新しいモデルの定式化の提案と定式化
  - 簡単な例でイメージを
3. 本モデルの持つ特徴
  - 確率分布
  - 弹力性
  - トレードオフ
  - 期待最大化効用
  - 消費者余剰
  - 異質性の取り扱い
4. 推定例
5. まとめ
6. おまけ

# 1. Introduction

- McFadden and Train (2000)
- 一般化ランダム効用最大化離散選択モデルを導出
- このモデルはconditional indirect utility (CIU)を次式で表す

$$\underline{U^*(z_j, s, \varepsilon_j, v)} \quad (1)$$

- 観測項  $z_j$                   非観測項  $\varepsilon_j$
- 観測個人属性  $s$     非観測個人属性  $v$
- データに適用するために、モデルをさらに特定化
- 選択肢  $j$  の確定効用を次式で表す

$$\underline{V_j = V(z_j, s, v)} \quad (2)$$

- この仮定の下で研究者はパラメータ推定をする

# 1. Introduction

- 変数  $z_j, s, v$  は  $V_j$  にまとめられるという仮定を置いて、CIUは(3)式で表す

$$\underline{U^*(V_j, \varepsilon_j)} \quad (3)$$

- このとき、選択確率は

$$\underline{p(i|z, s) = \int P(i|z, s, v)f(v)dv} \quad (4)$$

- $f(v)$  は母集団における  $v$  の確率分布

$$\underline{p(i|z, s, v) = Pr[U^*(V_i, \varepsilon_i) > U^*(V_j, \varepsilon_j) \forall j]} \quad (5)$$

# 1. Introduction

- 一般に加法型誤差項で定式化する

$$\underline{U^*(V_j, \varepsilon_j) = V_j + \varepsilon_j} \quad (6)$$

- ここで,  $\varepsilon_j$  と  $V_j$  は独立である

- 個人の非観測異質性  $v$  を無視した効用の線形パラメータでの特定化が一般的であり,

$$\underline{V_j = V(z_j, s, v) = \beta' x(z_j, s)} \quad (7)$$

- つまり, 式(4),(5)は次のように簡単にできる

$$\underline{P(i|z, s) = Pr(\beta' x(z_i, s) + \varepsilon_i > \beta' x(z_j, s) + \varepsilon_j \forall j)} \quad (8)$$

- 実際には  $\varepsilon$  の分布において, 一定の仮定をおく
- i.i.d. extreme value 分布 → MNL モデル

## ちょっと脱線して復習

- 車の効用,バスの効用が次式で表される

$$U_c = V_c + \varepsilon_c \quad V_c = \beta_1 T_c + \beta_2 M_c$$

$$U_b = V_b + \varepsilon_b \quad V_b = \beta_1 T_b + \beta_2 M_b$$

- T: 所要時間, M:金銭的コスト
- たとえば  $V_c=4$ ,  $V_b=3$  のとき, 車の方が確定効用が大きい

# 1. Introduction

- 式(3)から式(6)の流れは自然であるが…

$$U^*(V_j, \varepsilon_j) \quad (3)$$

$$U^*(V_j, \varepsilon_j) = V_j + \varepsilon_j \quad (6)$$

- 誤差項が異質的でi.i.d.の仮定を壊していることが  
ありうる。
- これまで多くの研究者が加法型誤差項の分散を  
観測, 非観測, 個人属性の関係などを特定化して  
i.i.d.の仮定を緩和してきた
- この論文では加法型仮定を**乗法型**に修正

## 2. Model formation

- 式(9)で与えられるJ個の選択肢の有限集合C上において、一般的な**乗法型誤差項**を仮定する。
  - $V_j < 0$  : 効用関数の確定項
  - $\varepsilon_j > 0$  : ランダム変数 個人ごとにi.i.d.で $V_j$ とは独立
  - これらの仮定は多くの適用において自然な仮定

- 式(5)の選択確率はこのモデルの下では次式

$$P(i|z, s, v) = \Pr(V_i \varepsilon_i \geq V_j \varepsilon_j \forall j) \quad (10)$$

- 乗法型の定式化も、次のような導出を行うことで、**加法型の古典的な定式化と関連**させることができ  
る

## 2. Model formation

$$\begin{aligned} P(i|z, s, v) &= \Pr(\underline{V_i \varepsilon_i \geq V_j \varepsilon_j}) \\ &= \Pr(\underline{-V_i \varepsilon_i \leq -V_j \varepsilon_j}) \\ &= \Pr(\underline{\ln(-V_i \varepsilon_i) \leq \ln(-V_j \varepsilon_j)}) \\ &= \Pr(\underline{-\ln(-V_i \varepsilon_i) \geq -\ln(-V_j \varepsilon_j)}) \\ &= \Pr(\underline{-\ln(-V_i) - \ln(\varepsilon_i) \geq -\ln(-V_j) - \ln(\varepsilon_j)}) \end{aligned}$$

$$-\ln(\varepsilon_j) = \frac{\xi_j}{\lambda} \quad (11)$$

$\xi_j$  : ランダム変数  
 $\lambda > 0$  : スケールパラメータ

$$\begin{aligned} P(i|z, s, v) &= \Pr(\underline{-\ln(-V_i) - \ln(\varepsilon_i) \geq -\ln(-V_j) - \ln(\varepsilon_j)}) \\ &= \Pr(\underline{-\ln(-V_i) + \frac{\xi_i}{\lambda} \geq -\ln(-V_j) + \frac{\xi_j}{\lambda}}) \\ &= \Pr(\underline{-\lambda \ln(-V_i) + \xi_i \geq -\lambda \ln(-V_j) + \xi_j}) \\ &= \Pr(\underline{\bar{V}_i + \xi_i \geq \bar{V}_j + \xi_j}) \quad (12) \end{aligned}$$

$$\bar{V}_i = -\lambda \ln(-V_i) \quad (13)$$

## 2. Model formation

- 以上より、対数形を用いることで**加法型のRUM**フレームワークで表現できる

$$P(i|z, s, v) = \Pr(\bar{V}_i + \xi_i \geq \bar{V}_j + \xi_j)$$

- 乗法型定式化では正の定数を両辺に掛けることは  $\ln(V)$ に定数を加えることと等価なので、正規化のためにあるパラメータを1か-1にfixするとよい
- 役に立つのは、**費用のパラメータを1に正規化**すると、他の係数はすべて**willing to pay 指標**として解釈することが可能

## 2. Model formation

- この定式化は非常に一般的であり、これまでの古典的なモデルにおけるMNL, MEV(GEV), mixedなどすべての離散選択モデルで利用できる
- たとえば、MNLの場合

$$P(i|z, s) = \frac{e^{-\lambda \ln(-V_i)}}{\sum_{j \in C} e^{-\lambda \ln(-V_j)}} = \frac{(-V_i)^{-\lambda}}{\sum_{j \in C} (-V_j)^{-\lambda}} \quad (14)$$

---

- また、この定式化は効用関数の線形パラメータを置く必要性があまりない（非線形でもOK）
- というか、線形パラメータを置いても、対数を取ったりする時点で非線形になってしまう
- Biogemeなら推定できるよ

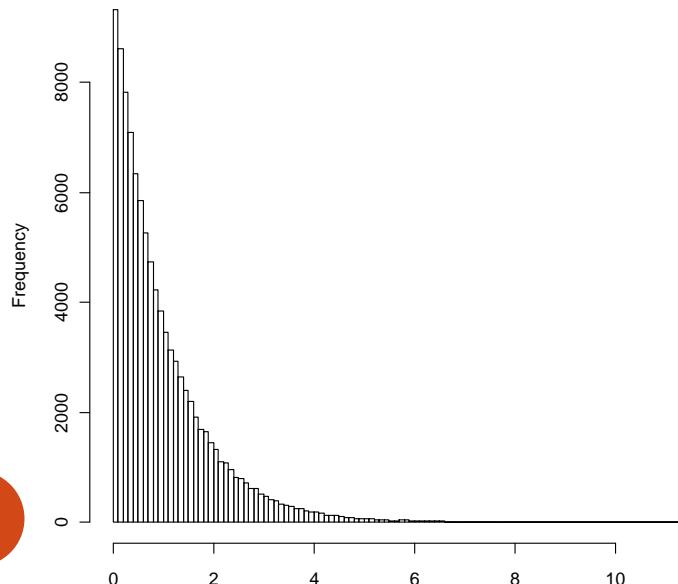
# ちょっと脱線して数値例でイメージ

	バス	自動車	パラメータ
費用 (円)	200	50	-1 (fix)
時間 (分)	15	10	-12
アクイグ時間 (分)	10	2	-15

$$V_b =$$

$$V_c =$$

$$P(i|z, s, v) = Pr(V_i \varepsilon_i \geq V_j \varepsilon_j \forall j) \quad (10)$$



たとえば

$$\varepsilon_b = 1, \varepsilon_c = 2 \rightarrow$$

$$\varepsilon_b = 0.5, \varepsilon_c = 1 \rightarrow$$

$$\varepsilon_b = 0.1, \varepsilon_c = 0.5 \rightarrow$$

ちなみに  $\varepsilon$  は指數分布 (exponential distribution)  
に従う (左図参照) 理由は後述。

### 3.1. Distribution

- 式(11)より  $\varepsilon_i$  の CDF は

$$-\ln(\varepsilon_j) = \frac{\xi_j}{\lambda} \quad (11)$$

$$\underline{F_{\varepsilon_i}(x) = 1 - F_{\xi_i}(-\lambda \ln x)}$$

- $\xi_i$  が extreme value 分布の場合、 $\xi_i$  の CDF は

$$\underline{F_{\xi_i}(x) = e^{-e^{-x}}}$$

- よって、 $\varepsilon_i$  の CDF は

$$\underline{F_{\varepsilon_i}(x) = 1 - e^{-e^{\lambda \ln x}} = 1 - e^{-e^{\ln x^\lambda}} = 1 - e^{-x^\lambda}}$$

- これは指数分布の一般形である

## 3.2. Elasticities

- 選択肢  $i$  の説明変数  $x_k$  の直接弾力性は定義より

$$e_{ik} = \frac{\partial P(i)}{\partial x_k} \frac{x_k}{P(i)} = \frac{\partial P(i)}{\underline{\partial V_i}} \frac{\underline{\partial V_i}}{\partial x_k} \frac{x_k}{P(i)}$$

- 式(13)を用いて

$$\bar{V}_i = -\lambda \ln(-V_i) \quad (13)$$

$$e_{ik} = \frac{\partial P(i)}{\underline{\partial \bar{V}_i}} \frac{\underline{\partial \bar{V}_i}}{\underline{\partial V_i}} \frac{\underline{\partial V_i}}{\partial x_k} \frac{x_k}{P(i)} = -\frac{\lambda}{\underline{V_i}} \frac{\partial P(i)}{\underline{\partial \bar{V}_i}} \frac{\underline{\partial V_i}}{\partial x_k} \frac{x_k}{P(i)}$$

- ここでMNLの場合  $\frac{\partial P(i)}{\underline{\partial \bar{V}_i}} = P(i)(1 - P(i))$  より

$$e_{ik} = -\frac{\lambda}{\underline{V_i}} (1 - P(i)) \underline{\frac{\partial V_i}{\partial x_k} x_k}$$

- 同様に交差弾力性は

$$e_{ijk} = -\frac{\lambda}{\underline{V_i}} (P(j)) \underline{\frac{\partial V_j}{\partial x_k} x_k}$$

### 3.3. Trade-offs

- トレードオフも加法型と同様に計算できる

$$\frac{\frac{\partial U_i}{\partial x_{ik}}}{\frac{\partial U_i}{\partial x_{il}}} = \frac{\frac{\partial V_i}{\partial x_{ik}} \cdot \varepsilon_i + V_i \cdot \frac{\partial \varepsilon_i}{\partial x_{ik}}}{\frac{\partial V_i}{\partial x_{il}} \cdot \varepsilon_i + V_i \cdot \frac{\partial \varepsilon_i}{\partial x_{il}}} = \frac{\frac{\partial V_i}{\partial x_{ik}}}{\frac{\partial V_i}{\partial x_{il}}}$$

$$\frac{\partial \varepsilon_i}{\partial x_{ik}} = \frac{\partial \varepsilon_i}{\partial x_{il}} = 0 \quad \text{なので}$$

### 3.4. Expected maximum utility

- 式(9)における効用の定義下での最大効用は

$$\underline{U^* = \max_{i \in C} U_i = \max_{i \in C} V_i \varepsilon_i = \max_{i \in C} V_i e^{-\frac{\xi_i}{\lambda}}} \quad (15)$$

- $\xi$  はGEV分布に従うと仮定すると

$$F(\xi_1, \dots, \xi_J) = e^{-G(e^{-\xi_1}, \dots, e^{-\xi_J})} \quad (16)$$

- G関数とは特徴的な性質を満たした関数
- このとき、期待最大化効用は次式で導出される

$$\underline{E[U^*] = -(G^*)^{-\frac{1}{\sigma\lambda}} \Gamma\left(1 + \frac{1}{\sigma\lambda}\right)} \quad (17)$$

### 3.5. Marshallian consumer surplus

- ・消費者余剰は $-V_i$ を一般化費用と解釈して導出
- ・このとき小さな変化 $dV_i$ における補償変分は選択肢*i*が選ばれるとき $-dV_i$ , それ以外は0
- ・よって, 限界的な変化 $dV_i$ における補償変分は

$$-\underline{P(i)dV_i} \quad (19)$$

- ・ $a$ から $b$ への $V_i$ の変化の補償変分は

$$-\int_a^b \underline{P(i)dV_i} \quad (20)$$

- ・たとえば $P(i)$ が古典的なMNLで与えられたとき,  
よく知られたログサム公式になる

$$\begin{aligned} -\int_a^b \underline{P(i)dV_i} &= -\int_a^b \frac{e^{V_i}}{\underline{e^{V_i} + e^{V_j}}} dV_i = -\underline{\left[ \log(e^{V_i} + e^{V_j}) \right]_a^b} \\ &= \underline{\log(e^a + e^{V_j}) - \log(e^b + e^{V_j})} \end{aligned}$$

### 3.6. Heterogeneity of the scale of utility

- 効用を次のように分解することを仮定

$$\underline{U^*(V_j, \varepsilon_j) = \tilde{V}(z_j, s)\mu(s, v)\varepsilon_j} \quad (21)$$

- 個人の観測異質性  $s$ , 非観測異質性は効用のスケールにのみ影響を与える
- 加法型の定式化の下で式(5)(6)を合わせると

$$\underline{P(i | z, s, v) = \Pr(\tilde{V}(z_i, s)\mu(s, v) + \varepsilon_i > \tilde{V}(z_j, s)\mu(s, v) + \varepsilon_j)} \quad (22)$$

- 乗法型の定式化の下で式(5)(9)を合わせると

$$\underline{P(i | z, s, v) = \Pr(\tilde{V}(z_i, s)\mu(s, v)\varepsilon_i > \tilde{V}(z_j, s)\mu(s, v)\varepsilon_j)} \quad (23)$$

$$\underline{= \Pr(\tilde{V}(z_i, s)\varepsilon_i > \tilde{V}(z_j, s)\varepsilon_j)} \quad (24)$$

- 乗法型の定式化では効用のスケールは確率とは無関係である

# 4. Empirical applications

## 1. 線形パラメータのロジットモデル

データ：デンマークのSPデータ（車と鉄道）

$$V_i = \lambda(-COST + \beta_1 AE + \beta_2 changes + \beta_3 headway + \beta_4 inVehTime + \beta_5 waiting) \quad (25)$$

コストのパラメータは-1に固定。 $\lambda$ は推定しにいく。

対数に変形すると次式(26)

$$\bar{V}_i = -\lambda \log(COST - \beta_1 AE - \beta_2 changes - \beta_3 headway - \beta_4 inVehTime - \beta_5 waiting) \quad (26)$$

説明変数	加法型誤差項		乗法型誤差項	
	推定値	t値	推定値	t値
Ae	-2.00	-9.46	-0.672	-11.11
Changes	-36.1	-5.23	-5.22	-3.40
Headway	-0.656	-8.71	-0.224	-10.53
In-veh. time	-1.55	-9.76	-0.782	-11.07
Waiting time	-1.68	-2.18	-1.06	-5.14
$\lambda$	0.0141	9.82	5.37	22.74
observations	3455		3455	
L(0)	-2394.824		-2394.824	
LL	-1970.846		-1799.086	
$\rho^2$	0.177		0.249	
$\rho^2$	0.175		0.246	

## 5. Concluding remarks

- 今まででは加法型の誤差項→乗法型もある！
- 推定もできる！(Biogemeで！)
- アプリオリに効用関数の構造を与えて同じデータで推定したところ、乗法型の方が当てはまりが良い場合多かった
- しかも、改善度合いは微少ではなく結構大きい！
- 場合によってはmixed logitや潜在クラスにするよりも改善することも
- とにかく推定してみよう

ということで、やってみたが…

- Rだと非線形なので、収束がうまくいかず推定できない・・・