

松山市内における 買物先選択行動モデル

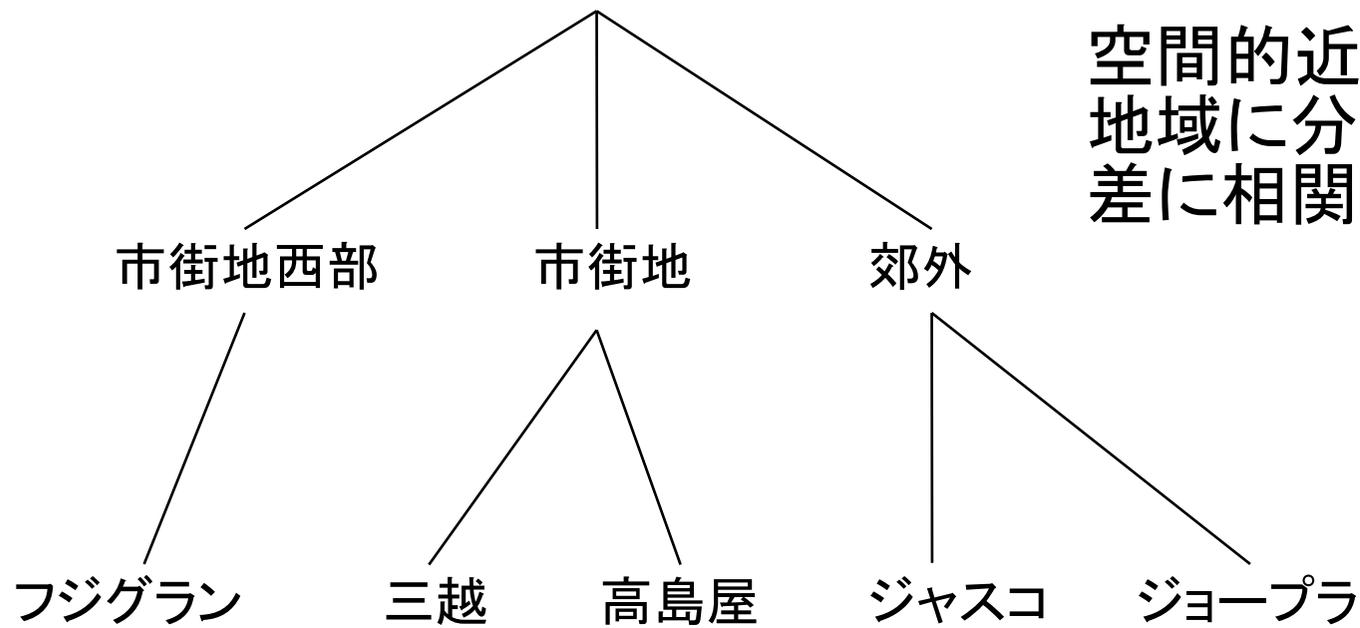
東京大学 都市生活行動学研究室

基礎集計

月曜	0.070	0.088	0.080	0.082	0.143
火曜	0.279	0.088	0.120	0.072	0.119
水曜	0.140	0.147	0.160	0.113	0.167
木曜	0.093	0.118	0.100	0.134	0.071
金曜	0.070	0.088	0.080	0.103	0.167
土曜	0.186	0.294	0.220	0.206	0.238
日曜	0.163	0.176	0.240	0.289	0.095

ネステッドモデルを用いた推定

NLモデルの誤差構造



空間的近接性により3つの地域に分け、それぞれの誤差に相関があると考ええる。

効用関数

$$\begin{aligned}U(takasi) &= V_{takasi} + \epsilon_{center} + \epsilon_{center,takasi} \\U(mituko) &= V_{mituko} + \epsilon_{center} + \epsilon_{center,mituko} \\U(f_matu) &= V_{f_matu} + \epsilon_{west} + \epsilon_{west,f_matu} \\U(jyasuko) &= V_{jyasuko} + \epsilon_{south} + \epsilon_{south,jyasuko} \\U(joepla) &= V_{joepla} + \epsilon_{south} + \epsilon_{south,joepla}\end{aligned}$$

確定項に用いた説明変数

$$\begin{aligned}V(takasi) &= \beta_1 * d_{takasi} && + \beta_{10} \\V(misuto) &= \beta_2 * d_{mituko} + \beta_6 * age40 + \beta_9 * noncar + \beta_{11} \\V(f_matu) &= \beta_3 * d_{f_matu} && + \beta_{12} \\V(jyasuko) &= \beta_4 * d_{jyasuko} + \beta_7 * tuesday && + \beta_{13} \\V(joepla) &= \beta_5 * d_{joepla} + \beta_8 * woman\end{aligned}$$

推定結果

	パラメータ	パラメータ値	t値
$\beta 1$	距離パラメータ	-0.317	-2.54
$\beta 2$	距離パラメータ	-0.662	-3.79
$\beta 3$	距離パラメータ	-0.397	-2.89
$\beta 4$	距離パラメータ	-0.384	-2.55
$\beta 5$	距離パラメータ	-0.410	-2.73
$\beta 6$	40才以上ダミーパラメータ	1.605	3.30
$\beta 7$	火曜日ダミーパラメータ	1.058	2.96
$\beta 8$	女性ダミーパラメータ	1.176	2.19
$\beta 9$	車でないダミーパラメータ	-1.019	-3.02
$\beta 10$	定数項	1.409	2.54
$\beta 11$	定数項	0.122	0.18
$\beta 12$	定数項	1.486	2.75
$\beta 13$	定数項	0.919	1.46
$\beta 14$	スケールパラメータ	2.523	3.22
	サンプル数	287	
	決定係数	0.26	
	修正済み決定係数	0.22	

考察

- NLモデルとMNLモデルを比べたが決定係数の値に大きな違いは見られなかった.
- ネストとしては市街地と郊外の2つに分けるよりは、空間的な近接性で3つに分けたほうが、わずかだがモデルの精度は上がった.
- しかし新たにダミー変数を導入するほうが有効であったため、ネストの組み方に改善の余地がある.

Multi nominal logit モデルの適用

- 買い物地選択行動をmulti nominal logit モデルを用いてモデル化する.

$$V_{\text{高島}_n} = \beta_1 + \beta_3 d_{\text{高島}_n}$$

$$V_{\text{三越}_n} = \beta_2 + \beta_3 d_{\text{三越}_n} + \beta_5 a_n$$

$$V_{\text{ジヨ}_n} = \beta_3 d_{\text{ジヨ}_n} + \beta_6 f_n$$

説明変数の検討(1)

- サンプルプログラムを改良する方針で説明変数を検討.
- 店までの距離そのものを説明変数として使うのではなく、距離を営業時間や売り場面積で除した値を使用.

$$d_{i_n} \longrightarrow \frac{d_{i_n}}{T_i * S_i}, \frac{d_{i_n}}{S_i}, \frac{d_{i_n}}{T_i}$$

d_{i_n} : 利用者 n の施設 i までの距離

T_i : 施設 i の営業時間

S_i : 施設 i の敷地面積

説明変数の検討(2)

- 検討の結果, $\frac{d_{i-n}}{T}$ を採用すると説明能力が向上.
- この値は, 買い物可能な時間の長さを表しているといえる.
- ダミー変数についても多重共線性を考慮した上で検討.

効用関数

$$V_{takashi} = \beta_1 + \beta_5 \frac{d_{takashi_n}}{T_{takashi} * 100}$$

$$V_{mituko} = \beta_2 + \beta_6 \frac{d_{mituko_n}}{T_{mituko} * 100} + \beta_{10} a_n + \beta_{11} c_n$$

$$V_{f_matu} = \beta_3 + \beta_7 \frac{d_{f_matu_n}}{T_{f_matu_n} * 100}$$

$$V_{jyasuko} = \beta_4 + \beta_8 \frac{d_{jyasuko_n}}{T_{jyasuko} * 100} + \beta_{12} f_n + \beta_{13} t_n$$

$$V_{joepla} = \beta_9 \frac{d_{joepla_n}}{T_{joepla} * 100} + \beta_{14} w_n + \beta_{15} a_n$$

d_{i_n} : 利用者 n の施設 i までの距離[m]

T_i : 施設 i の営業時間[h]

a_n : 40歳以上ダミー

c_n : 自動車ダミー

f_n : フリーターダミー

t_n : 火曜日ダミー

w_n : 女性ダミー

推定結果

		パラメータ値	t値
β 1	定数項	2.157	2.60
β 2	定数項	4.289 (*10 ⁻¹)	4.47 (*10 ⁻¹)
β 3	定数項	2.365	2.69
β 4	定数項	2.519	3.00
β 5	サービスレベル変数	-7.843 (*10 ⁻¹)	-7.00
β 6	サービスレベル変数	-9.499 (*10 ⁻¹)	-5.28
β 7	サービスレベル変数	-1.233	-6.68
β 8	サービスレベル変数	-1.531	-7.28
β 9	サービスレベル変数	-1.069	-5.93
β 10	40歳以上ダミー	1.991	3.82
β 11	自動車ダミー	-1.033	-2.42
β 12	フリーターダミー	3.064	3.28
β 13	火曜日ダミー	1.924	3.83
β 14	女性ダミー	1.519	2.31
β 15	40歳以上ダミー	1.199	2.37
サンプル数		287	
決定係数		0.295	
自由度修正済み決定係数		0.259	

考察

- サービスレベル変数として導入した $\frac{d_{i-1}}{T_i}$ の有意な説明能力が示された.
- モデルとしてもある程度の適合度があると考えられる.
- 関数形を考慮するなど, ダミー変数を導入する以上の工夫をすることが今後の課題である.

Mixed Logit Modelのパラメータ推定

効用関数が以下の式の形で示される。

$$U_a = \beta X_a + \eta_a + v_a$$



標準正規分布 $N(0, 1)$ であり、

確率計算がopen-formの積分になるので計算が難しい。



$N(0, 1)$ に従う乱数を発生させてやり、モンテカルロ法で

シミュレーション

(η の値をいろいろ変えて確率計算して、平均をとる)

シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は2,3,5...と必要に応じて増やす)



シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は2,3,5...と必要に応じて増やす)



シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は $2, 3, 5 \dots$ と必要に応じて増やす)



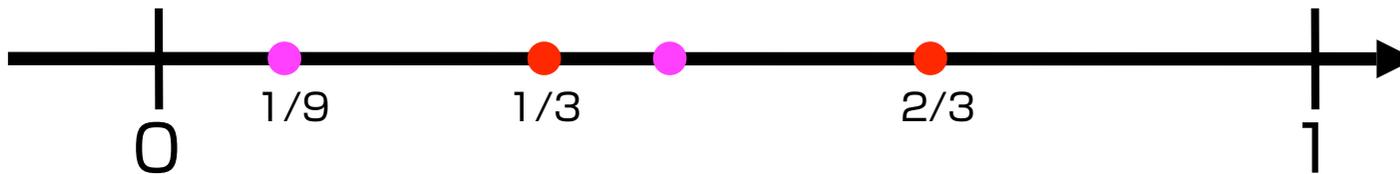
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は2,3,5...と必要に応じて増やす)



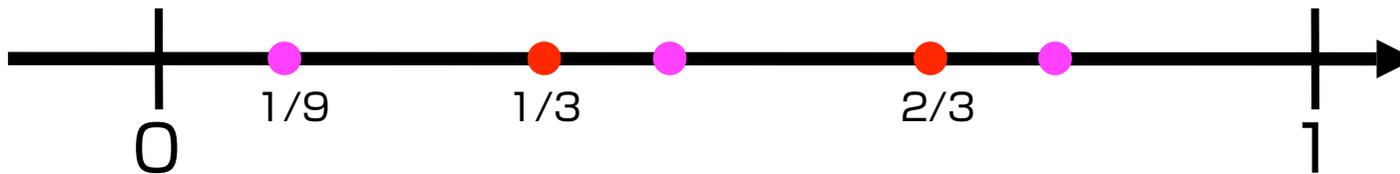
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は2,3,5...と必要に応じて増やす)



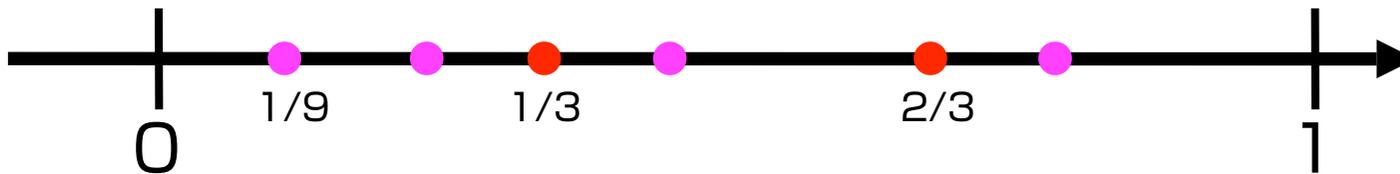
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は $2, 3, 5 \dots$ と必要に応じて増やす)



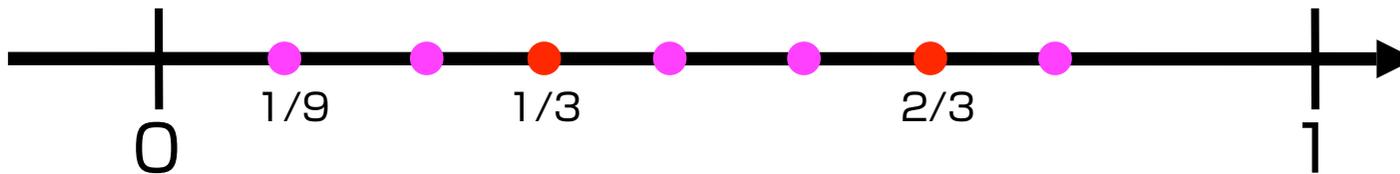
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は $2, 3, 5 \dots$ と必要に応じて増やす)



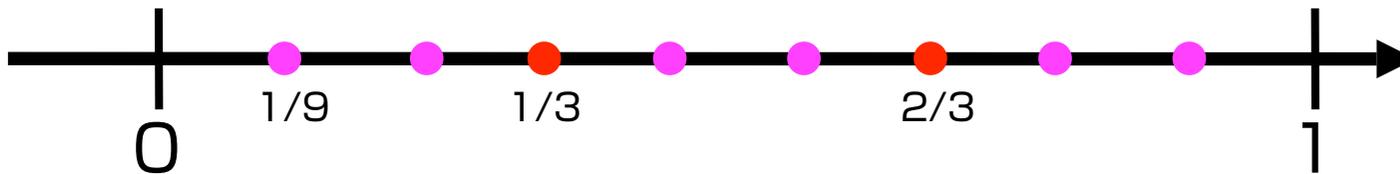
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は $2, 3, 5 \dots$ と必要に応じて増やす)



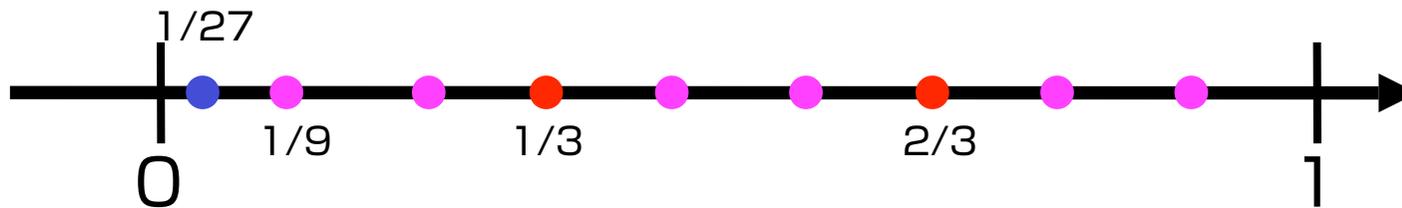
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は2,3,5...と必要に応じて増やす)



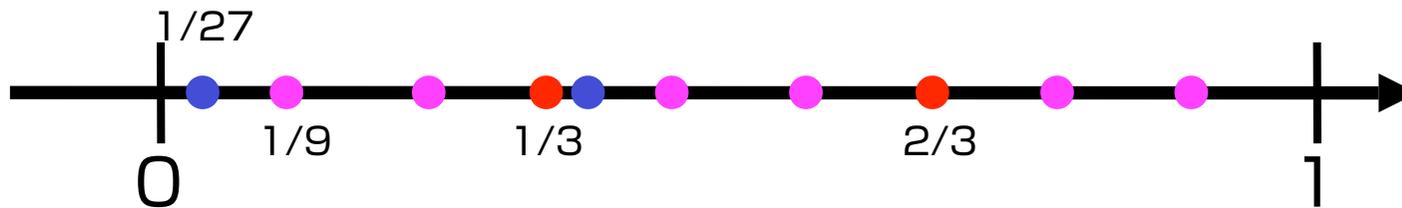
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は $2, 3, 5 \dots$ と必要に応じて増やす)



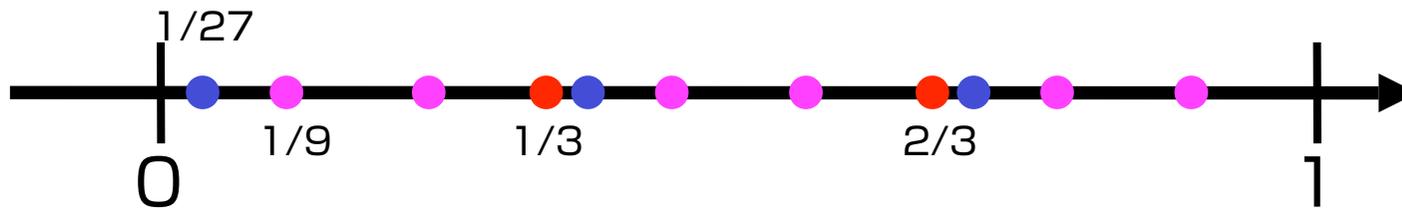
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は $2, 3, 5 \dots$ と必要に応じて増やす)



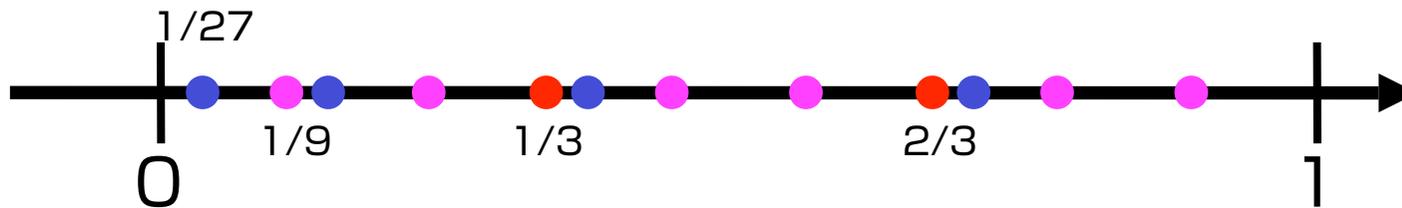
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は2,3,5...と必要に応じて増やす)



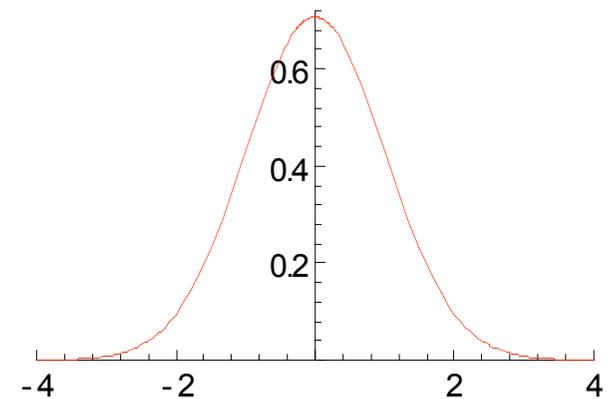
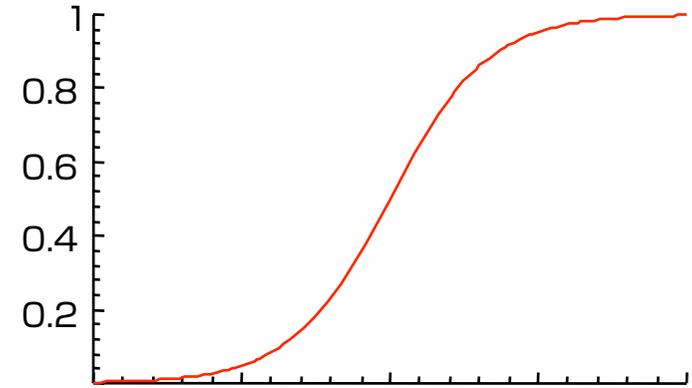
シミュレーションに使う乱数

- ハルトン数列
 - 乱数ではないが、必要な値域を効率よくカバーでき、パラメータ推定を行うときに乱数を使用したときより試行回数を減らせる
 - 例: $p=3$ のとき(p は $2, 3, 5 \dots$ と必要に応じて増やす)



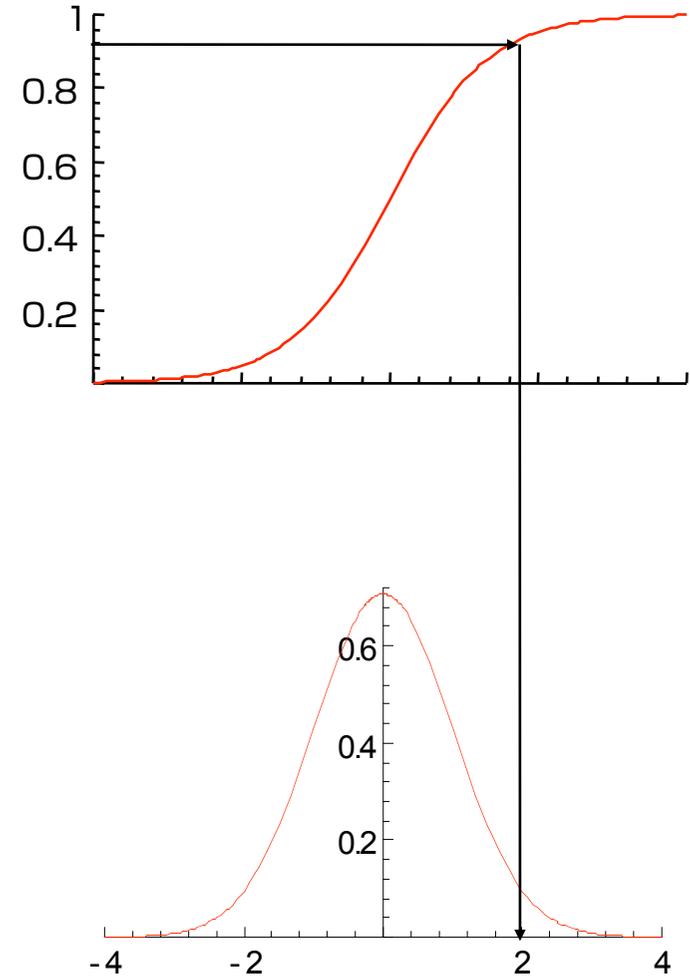
シミュレーションに使う乱数

- 一様分布の0~1の数列ができるので正規分布化



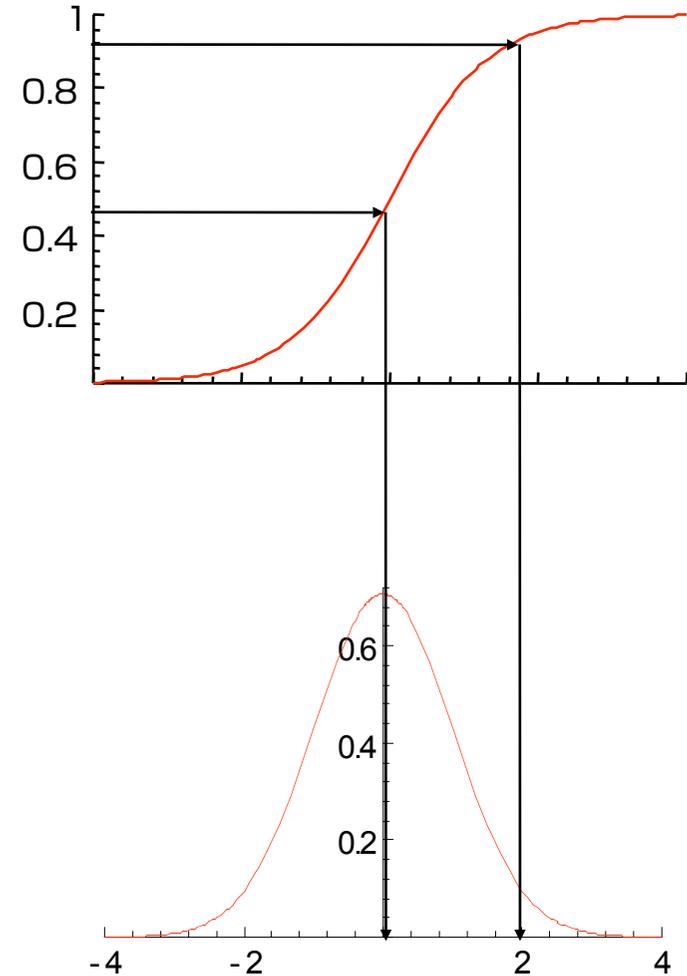
シミュレーションに使う乱数

- 一様分布の0~1の数列ができるので正規分布化



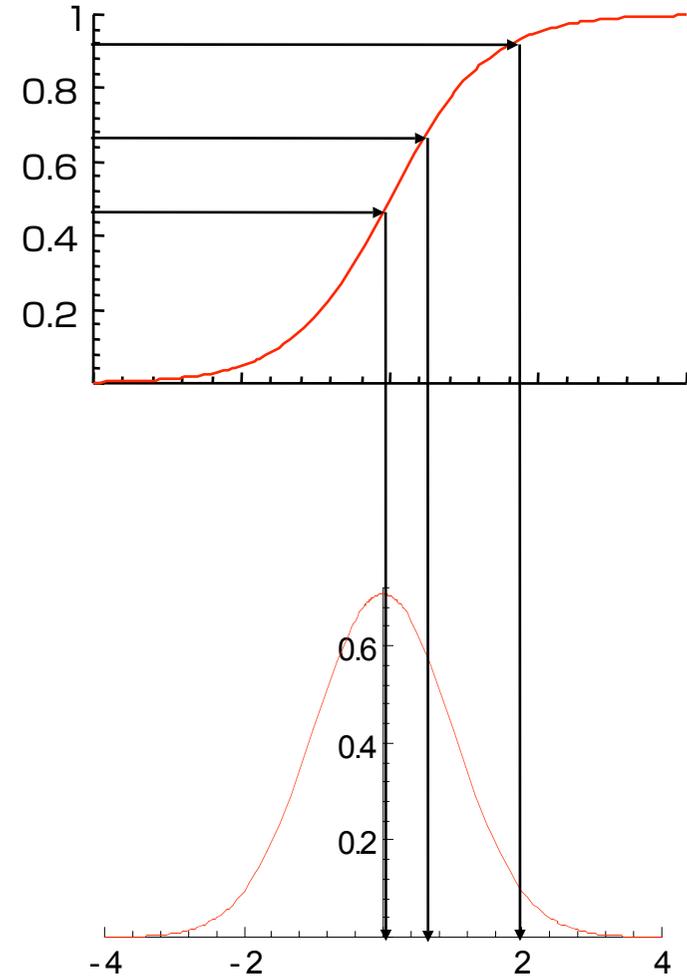
シミュレーションに使う乱数

- 一様分布の0~1の数列ができるので正規分布化



シミュレーションに使う乱数

- 一様分布の0~1の数列ができるので正規分布化



Mixed Logit Modelのパラメータ推定

- η をいろいろ変えて尤度を計算

$$U_a = \beta X_a + \eta_a + v_a$$

$$U_b = \beta X_b + \eta_b + v_b$$

$$P(a | \eta) = \frac{e^{\beta X_a + \eta_a}}{e^{\beta X_a + \eta_a} + e^{\beta X_b + \eta_b}}$$

- η が $N(0, 1)$ に従うように乱数を生成しているので、 $P(a | \eta)$ の平均は真の $P(a)$ に近づく
(η を動かす積分と似たようなもの)

Mixed Logit Modelのパラメータ推定

- アルゴリズム実装時には η に乱数を代入することは、 η という説明変数が増えた状態に似ている
- (例) 100件のデータに対して100回 η を変える場合
 - 100×100 で10000回効用を計算する
 - この10000件の対数尤度を最大にするようにしてパラメータ推定をする

なんとかRに移植できた

- …ということをGAUSS用のMixed Logit Modelのプログラムや佐々木先生の資料を読みながらなんとか理解して、移植することができました

モデル立式

- 中心市街地にあるフジグラン松山，伊予鉄高島屋，三越 と 郊外にあるジャスコ松山，ジョープラの間に，誤差間の相関があると仮定し，Mixed Logit Modelに組み込む.
- 基礎集計の結果から，考慮できそうなダミー変数を導入する.

モデル式

$$V_{\text{takashi}} = \beta_1 X_{\text{takashi}} + \eta_1 + \beta_6 D_{\text{Holiday}} + \nu_{\text{takashi}}$$

$$V_{\text{mituko}} = \beta_2 X_{\text{mituko}} + \eta_1 + \beta_7 D_{\text{Forty}} + \nu_{\text{mituko}}$$

$$V_{\text{fmatu}} = \beta_3 X_{\text{fmatu}} + \eta_2 + \nu_{\text{fmatu}}$$

$$V_{\text{jyasuko}} = \beta_4 X_{\text{jyasuko}} + \eta_2 + \beta_8 D_{\text{Friday}} + \nu_{\text{jyasuko}}$$

$$V_{\text{joepla}} = \beta_5 X_{\text{joepla}} + \eta_2 + \beta_9 D_{\text{Female}} + \nu_{\text{joepla}}$$

パラメータ推定結果

	パラメータ値	t値
takashi定数項	1.640	2.327
mituko定数項	0.140	0.163
fmatu定数項	1.530	2.052
joepla定数項	1.019	1.490
jyasuko火曜ダミー	1.744	3.686
mituko40歳以上ダミー	1.772	3.472
joepla女性ダミー	1.416	2.159
空間的相関パラメタ (中心)	0.121	0.253
空間的相関パラメタ (郊外)	0.227	0.576
takashi距離	-0.854	-7.950
mituko距離	-1.231	-6.314
fmatu距離	-0.981	-6.689
jyasuko距離	-0.911	-6.072
joepla距離	-0.928	-6.092
takashi休日ダミー	0.452	1.640

サンプル数：287

ρ^2 値：0.244

修正済み ρ^2 値：0.209

考察

- Mixed Logit Modelを用いたが、今回は有意な説明能力を示すことが出来なかった。
- 分類された空間同士の相関が十分になかった？
- また、推定プログラム作成に時間がかかり、モデルが吟味できなかったことも原因に挙げられる。