

投資意思決定での行動経済学的現象の識別 ～クラウドファンディングでの文脈効果についての 計量経済学的分析～

2021年 星野崇宏研究会三田祭論文発表

星野崇宏研究会7期

江守凌平 久米大雅 関優衣香 寺澤穂乃実

増田樹 村田裕人

目次



本研究の概要

解析手法

実証分析
結論・まとめ

目次

本研究の概要



- ・研究背景
- ・文脈効果と先行研究
- ・本研究の特徴
- ・FUNDINNOの選択システム
- ・仮説の提示

解析手法

実証分析 結論・まとめ

研究背景


〈 行動経済学のキーワード(一部)〉



研究背景

2003年「貯蓄から投資へ」
2016年「貯蓄から資産形成へ」
(金融庁)

<キーワード>
アノマリー(経験則)
ESG投資
インパクト投資



日米の金融資産比較

出典: 日本銀行調査統計局「資金循環の日米欧比較」(2020年)

研究背景

しかし、、、

投資行動において観察される「**認知バイアス**」や
「**感情バイアス**」は、望ましい投資行動の妨げになり得る

実際の投資行動における人間の非合理性を識別することで、より望ましい投資行動を促進することができれば、社会的に大きな意義がある

文脈効果 (Context Effect)

「選択肢の組み合わせによって選ぶ割合が変化すること」

1. 魅力効果 (Attraction Effect)

→ デコイがあると、上位のものを選びやすくなる

2. 妥協効果 (Compromise Effect)

→ 両極端の選択肢を回避し、中央を選びやすくなる

魅力効果 (Attraction Effect)

ターゲットに対し、それよりも明らかに劣る選択肢(デコイ)の影響により、ターゲットが選択される確率が増加する現象のこと。

AとBのスペックが対照的である場合に、Aの“おとり”としてDを追加すると、Aの選択率が上がる




図1 2つの属性の値で特徴づけられる選択肢の図解

魅力効果の先行研究(概要)

Schwarzkopf (2003) の実験

1万ドルを1年間投資する実験

STEP① 2つの候補の間で、投資額の100%を配分

STEP② ①の候補に加え、デコイの候補を追加し100%を3つに配分

STEP③ 3種類の投資候補ペアに対してそれぞれ100%を配分する

魅力効果の先行研究（仮説と結果）

仮説1（一般的な魅力効果）：STEP①と②

デコイにより、競合を比較してターゲットに有利な投資配分となるのでは？

→＜結果＞デコイに投資シェアが移動

仮説2（クラスター誘引）：STEP①と③

デコイが加わることで、3つの候補内における競合の投資配分が減少するのでは？

→＜結果＞ターゲットからデコイにシェアが移動

⇒投資的意思決定における魅力効果の存在が実証された

（デコイにより、投資家が意思決定を再検討する方法が変化した）

魅力効果の先行研究(意義と課題)

<意義>

投資家は頻繁にポートフォリオを見直したり、新たな投資先を開拓する
→魅力効果の実証は投資選択について大きな影響がある


<課題>

学生を対象に行った実証実験に過ぎない
投資の複雑さも単純化したような小規模な実験

→本研究(三田祭論文)には新規性がある

妥協効果 (Compromise Effect)

2 選択肢セットに元の 2 選択肢に中立的な第 3 の選択肢を追加したとき、中間の選択肢が採択されやすくなる効果のこと。



妥協効果の先行研究

Cheng et al.(2012)の実験
(設定)

①A.確実に250ドル獲得
獲得、75%で報酬ゼロ

77%

B.25%で1000ドル

差=60%

③A.確実に750ドル失う

17%

B.75%で1000ドル失い、75%で損失ゼロ

妥協効果の先行研究

Cheng et al.(2012)の実験
(設定 赤字は妥協選択肢)

②A.確実に250ドル獲得 59%

B.50%で5000台湾ドル獲得、50%で報酬ゼロ

C.25%で1000ドル獲得、75%で報酬ゼロ

④A.確実に750ドル失う 42%

B.90%で833ドル失い、10%で損失ゼロ

C.75%で1000ドル失い、75%で損失ゼロ

差 = 17%

妥協効果の先行研究

Cheng et al.(2012)の実験

(設定

②A.確

B.50

C.25

④A.確

B.90%

C.75%で1000ドル失い、75%で損失ゼロ

選択肢Aの選択率の差が60%から17%に減少



妥協選択肢が追加されたことにより、より極端な選択肢を回避するようになったということ

= 17%

極端回避性

提示された情報や選択肢の中で極端な性質を持つ選択肢を回避し、
中心を強く選好するという人間の性質

＜松竹梅の法則＞

お寿司で松・竹・梅が提示されたら、竹を選んでしまう

文脈効果~経済学における重要性~

ミクロ経済学(顕示選好の弱公理)

A・B・Cの3つの選択肢があり、選好が $A > B > C$ である場合、この選好が崩れることはない。(消費者はAを選び、BやCが選ばれることはないはず)

文脈効果が働くと？

選択肢の提示方法によっては、BやCが選ばれる可能性がある

→経済学・マーケティング領域において大きな意義がある！

研究目的(新規性)

＜先行研究の課題＞

- ・文脈効果に焦点を当てて金融商品の選択を分析した研究が少ない
- ・実験室実験など仮想的なもの・アンケート調査が多い

＜研究目的＞

「現実の投資行動における文脈効果の存在の実証、および非合理性を考慮した投資行動の促進」

＜研究意義＞

- ・投資行動を文脈効果の関連性を実証している
- ・現実の投資意思決定(最大50万円の投資)に着目している

ファンディーノの選択システム

- 投資家は3つの選択肢から一つを選ぶ
- 3つの選択肢の違いは投資金額のみ
- 投資金額が増えれば、期待リターンが増える→効用が増える

×

投資コースの選択

500,000円コース 株数：500株	申し込む
300,000円コース 株数：300株	申し込む
100,000円コース 株数：100株	申し込む

ご希望されるコースを選択していただくと、各コースのお申込みフォーム上に「契約締結前交付書面」が掲載してありますので、よくお読みください。
ご応募いただく前にあらかじめ、「契約締結前交付書面」を確認していただく必要があります。

本稿の仮説

〈仮説〉

「金融商品の選択行動においても文脈効果は存在する」

加えて、

「個人依存の変数が文脈効果の存在に影響を与えるか否か」についても実証する

目次



本研究の概要

解析手法

実証分析
結論・まとめ

解析手法

解析モデル

1. 制限従属モデル
2. 固定・変量効果モデル

推定方法

3. MCMC法

解析手法

解析モデル

1. 制限従属モデル
2. 固定・変量効果モデル

推定方法

3. MCMC法

制限従属変数モデルとは

従属変数とは被説明変数が一定の値に制限される変数のことを指す

例)

購入するか否か(0.買わない,1.買う)

評価指標(1悪い.2.普通3.良い)

選択肢(0.買わない,1.10万円コース,2.30万円コース,3.50万円コース)

制限従属変数モデルとは

従属変数とは被説明変数が一定の値に制限される変数のことを指す

例)

購買するか否か(0.買わない,1.買う)[2値モデル]

評価指標(1.悪い.2.普通3.良い)

選択肢(0.買わない,1.10万円コース,2.30万円コース,3.50万円コース)

制限従属変数を線形回帰しない理由

$$y_i = \beta_0 + \sum_{k=1}^K (\beta_k x_{ik}) + u_i \quad (i = 1, 2, \dots, N, y = (0, 1))$$

[理由]

(1) y が $[0, 1]$ の間に収まらない

(2) $Var(u_i | x_{i1}, x_{i2}, \dots, x_{ik}) = Pr_i(1 - Pr_i)$ となる

制限従属変数を線形回帰しない理由

$$y_i = \beta_0 + \sum_{k=1}^K (\beta_k x_{ik}) + u_i \quad (i = 1, 2, \dots, N, y = (0, 1))$$

[理由]

(1) y が $[0, 1]$ の間に収まらない

y は確率を表すため、確率の定義より不適

(2) $Var(u_i | x_{i1}, x_{i2}, \dots, x_{ik}) = Pr_i(1 - Pr_i)$ となる

線形確率の定義[誤差項の分散が均一であること]に反する

制限従属変数モデルとは

従属変数とは被説明変数が一定の値に制限される変数のことを指す

例)

購買するか否か(0.買わない,1.買う)

評価指標(1.悪い.2.普通3.良い)

選択肢(0.買わない,1.10万円コース,2.30万円コース,3.50万円コース)

直接効用モデルによる表現

構造推定の観点から制限従属変数モデルを推定する

予算制約式

$$\max U(x) = \sum_{j=1}^J p_j x_j$$

$$s. t. \sum_{j=1}^J p_j x_j \leq E$$

$$L = U(x) - \lambda \left(\sum_{j=1}^J p_j x_j - E \right)$$

KKT条件を用いると以下が導出できる

$$\psi_l - \lambda p_j = 0 \text{ if } x_l^* > 0 \text{ or } \psi_l - \lambda p_j < 0 \text{ if } x_l^* = 0$$

商品*l*を購入する場合

$$\frac{\psi_l}{p_l} > \frac{\psi_j}{p_j} \text{ for all } j$$


$\psi_{li} = \psi_l \exp\{\epsilon_{li}\}$ とおくと商品が購買される確率は以下ようになる。

(ϵ は消費者 i の限界効用の時間的または選択肢間の変動をもたらすランダムな要素)

$$p_l = \Pr(x_l^* > 0) = \Pr(\epsilon_j < V_l - V_j + \epsilon_l \text{ for any } j \neq l)$$

$$p_l = \int_{-\infty}^{\infty} \left[\int_{-\infty}^{V_l - V_1 + \epsilon_l} \cdots \int_{-\infty}^{V_l - V_J + \epsilon_l} \pi(\epsilon_1) \cdots \pi(\epsilon_J) d\epsilon_1 \cdots d\epsilon_J \right] \pi(\epsilon_l) d\pi(\epsilon_l)$$

$$p_l = \int_{-\infty}^{\infty} [F(V_l - V_1 + \epsilon_l) \cdots V_l - V_J + \epsilon_l] \pi(\epsilon_l) d\pi(\epsilon_l)$$



$$p_l = \int_{-\infty}^{\infty} [F(V_l - V_1 + \epsilon_l) \cdots V_l - V_J + \epsilon_l] \pi(\epsilon_l) d\pi(\epsilon_l)$$

累積密度関数 $F()$ に対して本稿では、

第一種極値分布と標準正規分布

を用いる。それぞれのモデルを

ロジットモデルとプロビットモデル

と呼ぶ

$$p_l = \int_{-\infty}^{\infty} [F(V_l - V_1 + \epsilon_l) \cdots V_l - V_J + \epsilon_l] \pi(\epsilon_l) d\pi(\epsilon_l)$$

累積密度関数 $F()$ に対して本稿では、

第一種極値分布と標準正規分布

を用いる。それぞれのモデルを

ロジットモデルとプロビットモデル

と呼ぶ

条件付きロジットモデル

条件付きロジットモデルとは、説明変数が選択肢 j と個人 i による k 個の変数 w_{ijk} を用いるモデルである。

$$\Pr(y_i = j | w_{ij1}, \dots, w_{ijK}) = \begin{cases} \frac{1}{1 + \sum_{j=2}^J [\exp(\beta_0 + \sum_{k=1}^K (\beta_k w_{ijk}))]} & (j = 1) \\ \frac{\exp(\beta_0 + \sum_{k=1}^K (\beta_k w_{ijk}))}{1 + \sum_{j=2}^J [\exp(\beta_0 + \sum_{k=1}^K (\beta_k w_{ijk}))]} & (j = 2, \dots, J) \end{cases}$$

条件付きロジットモデルの確率の比

$$\frac{\Pr(y_i = j)}{\Pr(y_i = h)} = \exp\left[\sum_{k=1}^K (\beta_k w_{ijk}) - \sum_{k=1}^K (\beta_k w_{ihk})\right]$$

選択肢jとhが選択される相対的な確率は他の選択肢の確率から影響を受けないことが分かる。(IIA仮定)

本稿の仮説においてはIIAの仮定をおくと矛盾が生じてしまうため、
条件付きロジットモデルは本稿において不適である。

$$p_l = \int_{-\infty}^{\infty} [F(V_l - V_1 + \epsilon_l) \cdots V_l - V_J + \epsilon_l] \pi(\epsilon_l) d\pi(\epsilon_l)$$

累積密度関数 $F()$ に対して本稿では、

第一種極値分布と標準正規分布

を用いる。それぞれのモデルを

ロジットモデルとプロビットモデル

と呼ぶ

条件付きプロビットモデル

条件付きロジットモデルとは、説明変数が選択肢 j と個人 i による k 個の変数 w_{ijk} を用いるモデルである。

$$\Pr(y_i = j | w_{ij1}, \dots, w_{ijK}) = \Phi \left(\sum_{k=1}^K \beta_k w_{ijk} \right)$$

$$u_i \sim TN_{J-1}(0, \Sigma)$$

$$\Sigma = \begin{bmatrix} 1 & \sigma_{23} & \cdots & \sigma_{2J} \\ \sigma_{32} & \sigma_{33} & \cdots & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ \sigma_{J2} & \cdots & \cdots & \sigma_{JJ} \end{bmatrix}$$

潜在変数モデル

条件付きプロビットモデルは、潜在変数である y_{ij}^* を個人 i ,選択肢 j の効用とみなすことができ、相対効用 v_{ij} を線形回帰するモデルである。

$$y_{ij}^* - y_{i1}^* = \sum_{k=1}^K \beta_k (w_{ijk}^* - w_{i1k}^*) + u_{ij}^* - u_{i1}^* = v_{ij} = \sum_{k=1}^K \beta_k w_{ijk} + u_{ij}$$

$$y_i = \begin{cases} j \neq 1 & \text{if } \max v_{ik} = v_{ij} > 0 \\ j = 1 & \text{if } \max v_{ik} < 0 \end{cases}$$

階層モデル

条件付きプロビットモデルで求めたパラメータ β に対して投資家属性変数 z がどの程度影響を与えてるか示すために以下のように階層モデルを用いる。

$$\beta_{ik} = \theta_{k0} + \sum_{q=1}^Q \theta_{kq} z_{iq} + \eta_{ik} \quad \eta_{ik} \sim MVN(0, \Sigma_{\beta})$$
$$\beta_{ik} = \theta_{k0} + \Theta' z_{iq} + \eta_{ik} \quad \eta_{ik} \sim MVN(0, \Sigma_{\beta})$$

解析手法

解析モデル

1. 制限従属モデル
2. 固定・変量効果モデル

推定方法

3. MCMC法

固定効果とは

固定効果とは、観察はできないが時間を通じて一定な変数である

$$y_{it} = \beta x_{it} + \boxed{\mu_i} + v_{it}$$

固定効果

固定効果除去方法

$$\mu_i = \alpha_0 + \alpha_1 D1_i + \cdots + \alpha_N DN_i$$

$$DI_i \begin{cases} 1 & (I = i) \\ 0 & (I \neq i) \end{cases}$$

固定効果とは

固定効果とは、観察はできないが時間を通じて一定な変数である

$$y_{it} = \beta x_{it} + \boxed{\mu_i} + v_{it}$$

固定効果

固定効果を除去すれば

時間に不変かつ個人依存の変数を取り除くことができる

非線形モデルにおける固定効果

非線形モデルにおける固定効果 α とパラメータ β は以下のように導出できる。

$$\beta = \underset{\beta}{\operatorname{argmax}} \frac{1}{N} \sum_{i=1}^N \sum_{t=1}^T \log f(y_{it} | x_{it}, \beta, \alpha_i)$$

$$\alpha_i(\beta) = \underset{\alpha_i}{\operatorname{argmax}} \sum_{t=1}^T \log f(y_{it} | \beta, \alpha_i)$$

Tが小さいとき固定効果 α は推定誤差を持つ。

本稿ではTを大きくする(閾値minTを設ける)ことで誤差を解消する

ランダム係数モデルとは

固定効果を確率変数としたものを変量効果と呼び、説明変数の係数に変量効果を組み込むモデルをランダム係数モデルと呼ぶ

$$y_{it} = \{\beta_0 + (\sum \gamma_K) x_{it} + v_{it}$$

ランダム係数

ランダム係数モデルを導入すれば固定効果同様
時間に不変かつ個人依存の変数を取り除くことができる

今回使用している解析モデル

(固定効果除去条件付きプロビットモデル)

$$\Pr(y_i = j | w_{ij1}, \dots, w_{ijK}) = \Phi \left(\beta_0 + \sum_{k=1}^K \beta_k w_{ijk} + \sum_{I=1}^N \alpha_I D I_{it} \right)$$

$$D I_i \begin{cases} 1 & (I = i) \\ 0 & (I \neq i) \end{cases} \quad \Sigma = \begin{bmatrix} 1 & \sigma_{23} & \cdots & \sigma_{2J} \\ \sigma_{32} & \ddots & \cdots & \vdots \\ \vdots & \ddots & \vdots & \vdots \\ \sigma_{J2} & \cdots & \cdots & \sigma_{JJ} \end{bmatrix}$$

(変量効果除去条件付きプロビットモデル)

$$\Pr(y_i = j | w_{ij1}, \dots, w_{ijK}) = \Phi \left(\beta_j + \left\{ \beta_0 + \left(\sum \gamma_K \right) w_{ijk} \right\} \right)$$

$$u \sim N(0, \Sigma) \quad \gamma \sim N(0, \Sigma)$$

$$\Sigma = \begin{bmatrix} 1 & \sigma_{23} & \cdots & \sigma_{2J} \\ \sigma_{32} & \ddots & \cdots & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ \sigma_{J2} & \cdots & \cdots & \sigma_{JJ} \end{bmatrix}$$

階層モデル

条件付きプロビットモデルで求めたパラメータ β に対して投資家属性変数 z がどの程度影響を与えてるか示すために以下のように階層モデルを用いる。

$$\beta_{ik} = \theta_{k0} + \sum_{q=1}^Q \theta_{kq} z_{iq} + \eta_{ik} \quad \eta_{ik} \sim MVN(0, \Sigma_{\beta})$$
$$\beta_{ik} = \theta_{k0} + \Theta' z_{iq} + \eta_{ik} \quad \eta_{ik} \sim MVN(0, \Sigma_{\beta})$$

解析手法

解析モデル

1. 制限従属モデル
2. 固定・変量効果モデル

推定方法

3. MCMC法

MCMC法

MCMC法とは、ベイズの定理を用いて事後分布を事前分布・尤度関数で近似することで、パラメータを推定する方法である。

$$\boxed{P(\theta|X)} = \frac{P(X|\theta)P(\theta)}{P(X)} \propto \boxed{P(X|\theta)} \boxed{P(\theta)}$$

事後分布 尤度関数 事前分布

本稿における同時事後分布

$$p\left(\gamma_j^{inv}, \gamma_j^{pj}, \Theta, \Sigma^{inv}, \Sigma^{pj}, V \mid y_{it}, z_i, w_{ijt}\right)$$

$$\propto p(\Theta)p(V)p(\Sigma^{inv})p(\Sigma^{pj})$$

$$\prod_{i=1}^N [p(\gamma_j^{inv} \mid \Theta, \Sigma^{inv}, Z_i)p(\gamma_j^{pj} \mid \Sigma^{pj}) \prod_{t=1}^{T_i} \int_{R_i^{J-1}} p(v_i \mid \gamma_j^{inv}, \gamma_j^{pj}, V, w_{ijt}) dv_i]$$

MCMC法のアルゴリズム

パラメータ $\gamma_j^{inv}, \gamma_j^{pj}, \Theta, \Sigma^{inv}, \Sigma^{pj}$ をMCMC法のアルゴリズムの1種であるランダムウォークM-H法によって評価する。

MCMC法のアルゴリズム

[ランダムウォークM-H法](j回まで推定しているとする)

1) $v \sim N(0, \sigma_v)$ でサンプリングし、 $\theta_i^* = \theta_i^j + v$ とする。


2) θ_i^* を採択するかどうかの確率を $\alpha(\theta_i^*, \theta_i^j)$ を以下のように算定する。

$$\alpha(\theta_i^*, \theta_i^j) = \min\left(1, \frac{\pi(\theta_i^*)}{\pi(\theta_i^j)}\right)$$

3) (0,1)区間の一様乱数 u を用いて以下のように確率的採択を行う。

$$\theta_i^{j+1} = \theta_i^*, u \leq \alpha(\theta_i^*, \theta_i^j)$$

$$\theta_i^{j+1} = \theta_i^j, u > \alpha(\theta_i^*, \theta_i^j)$$



DAG表記によるMCMC推定方法

目次

本研究の概要

解析手法

実証分析
結論・まとめ

三田論の実装に使った言語

- EDA/前処理⇒Python(Google Colaboratory)
 - 柔軟なEDAと多様なプロセスの前処理が必要
 - Google driveと融通が利く
- 追加の前処理/モデル構築⇒SAS
 - 大規模データに対する耐性
 - 前処理とモデル構築を一本化させやすい

データ解析ステップ(PythonとSAS)



加工前の元データ



Google DriveとGoogle Colaboratoryの連携

- データ結合や前処理、サンプリング等
- ワイド形式からロング形式に変換
- CSV形式に変換

Python



ドライブからローカルサーバに転送

- データの前処理
- モデルに入れて解析結果
- 結果をpdf形式で出力

SAS



結果をメール送信

解析結果



データの概要

- ・ 取引ログデータ
 - ・ 誰がどこに、いつ投資したか
- ・ 投資家データ
 - ・ 投資家の属性について
- ・ プロジェクト属性データ
 - ・ プロジェクトの属性について




図 8: データの関係図

✓ それぞれのデータはIDで紐づけが可能

加工後データ

・ 加工後データの概形

目的変数/使わない/説明変数/ 使わない / _____ 説明変数 _____ /固定効果or変量効果

選んだか/選択肢番号/投資金額/ 選択肢ダミー / value × opt2/value × opt3/投資家ID/投資案件ID

Choice	Nowopt	Value	Opt1	Opt2	Opt3	Valopt2	valopt3	Investor_id	Project_id	
0	1	1	1	0	0	0	0	1	1	選択肢1
1	2	3	0	1	0	3	0	1	1	選択肢2
0	3	5	0	0	1	0	5	1	1	選択肢3
0	4	0	0	0	0	0	0	1	1	投資なし
1	1	0.9	1	0	0	0	0	2	1	

データ加工の概要

1. Projectごとの選択肢データを作成
2. 選んだ選択肢の番号を付加&選択肢ダミーを作成
3. 「投資しない」選択肢の追加
4. 投資の意思決定回数の算出・サンプリング
5. ワイド型からロング型への変換
6. Csv形式で転送
7. 追加のサンプリング

モデル作成

- すべてSASで作成

表 4: 検証に用いるモデル

	投資家の効果	プロジェクトの効果	使用モデル	説明箇所
モデル 1	固定効果	固定効果	条件付きプロビットモデル	4.3.1 節
モデル 2	変量効果	変量効果	条件付きプロビットモデル	4.3.2 節
モデル 3	変量効果	変量効果	条件付きプロビットモデル	4.3.3 節

モデル1

- ・ 固定効果除去した条件付きプロビットモデル

$$\begin{aligned} Pr(y_{ijt} = 1) = & \Phi(\beta_1 value + \beta_2 opt_2 + \beta_3 opt_3 + \beta_4 valopt_2 + \beta_5 valopt_3 \\ & + \sum_{j=1}^J \sum_{p=1}^P \alpha_{jp} opt_dummy_j \times project_dummy_p \\ & + \sum_{j=1}^J \sum_{i=1}^N \alpha_{ji} opt_dummy_j \times investor_dummy_i) \end{aligned} \quad (118)$$

モデル2

- ・ 変量効果を除いたプロビットモデル

$$\begin{aligned}\pi = \Phi &((\beta_1 + \gamma^{inv1} + \gamma^{pj1})value + \beta_2 optinvested \\ &+ (\beta_4 + \gamma^{inv2} + \gamma^{pj2})valopt2 + (\beta_5 + \gamma^{inv3} + \gamma^{pj3})valopt3)\end{aligned}\tag{124}$$

結果

表 9: モデル 1 における係数の推定量

パラメータ	自由度	推定値	標準誤差	t 値	Pr< t
投資金額	1	2.5341	1.0862	2.33	0.0197
投資金額×選択肢 2 ダミー	1	-2.6857	0.7333	-3.66	0.0002
投資金額×選択肢 3 ダミー	1	-2.5736	0.7493	-3.43	0.0006

表 10: モデル 2 の係数の推定量

パラメータ	サンプル数	推定値	標準偏差	95% 確信区間	
				下限	上限
切片項	10000	0.6146	0.2874	0.0610	1.1778
投資金額	10000	0.1853	0.2841	-0.3607	0.7488
投資金額×選択肢 2 ダミー	10000	-1.1802	0.1906	-1.5661	-0.8207
投資金額×選択肢 3 ダミー	10000	-1.0581	0.2328	-1.5192	-0.6105

結果

表 12: モデル 2 における分散共分散行列の推定量

パラメータ	サンプル数	推定値	標準偏差	95% 確信区間	
				下限	上限
Σ_{11}^{inv}	10000	0.8606	0.0714	0.7227	1.0006
Σ_{12}^{inv}	10000	-1.0818	0.0892	-1.2675	-0.9201
Σ_{13}^{inv}	10000	-1.1621	0.0950	-1.3490	-0.9778
Σ_{21}^{inv}	10000	-1.0818	0.0892	-1.2675	-0.9201
Σ_{22}^{inv}	10000	1.4526	0.1182	1.2349	1.6912
Σ_{23}^{inv}	10000	1.4494	0.1192	1.2224	1.6859
Σ_{31}^{inv}	10000	-1.1621	0.0950	-1.3490	-0.9778
Σ_{32}^{inv}	10000	1.4494	0.1192	1.2224	1.6859
Σ_{33}^{inv}	10000	1.6406	0.1346	1.3850	1.9081

結果の考察

- ・ 投資金額の項は正の係数
 - ・ 投資金額が上がれば上がるほど、購買確率は高まるはず
 - ・ クラファンという金融商品の特性(期待リターンが高い)
- ・ 文脈効果の項が有意
 - 投資金額が一番少ない選択肢に比べて、他の選択肢は効用が低い
 - 負の文脈効果の存在が示された

結果の考察

- ・ 分散共分散行列はすべての項が0を含まない
&ある程度の大きさがある
⇒文脈効果が投資家ごとによりばらついていることがわかる
- ・ もし、投資家の属性を入れたら説明することが出来るのでは？
⇒階層ベイズ

モデル3

- ・ 階層モデルを用いて変量効果を除去したモデル

$$\begin{aligned}\pi = & \Phi((\beta_1 + \gamma^{inv1} + \gamma^{pj1})value + \beta_2 optinvested \\ & + (\beta_4 + \gamma^{inv2} + \gamma^{pj2})valopt2 + (\beta_5 + \gamma^{inv3} + \gamma^{pj3})valopt3)\end{aligned}\tag{124}$$

$$\beta_{ik} = \theta_{k0} + \sum_{q=1}^8 \theta_{kq} Z_{iq} + \eta_{ik} \quad \eta_{ij} \sim MVN(0, \Sigma^{inv})\tag{135}$$

結果

表 13: モデル 3 における係数の推定量

パラメータ	サンプル数	推定値	標準偏差	95% 確信区間	
				下限	上限
切片項	10000	-0.4926	0.1125	-0.7248	-0.2782
θ_{11}	10000	0.5315	0.2122	0.0966	0.9273
θ_{12}	10000	0.7088	0.1315	0.4595	0.9772
θ_{13}	10000	0.6780	0.0987	0.4759	0.8632
θ_{14}	10000	0.6984	0.1351	0.4484	0.9717
θ_{15}	10000	1.2138	0.2768	0.6739	1.7420
θ_{16}	10000	0.8477	0.1451	0.5658	1.1298
θ_{17}	10000	1.0652	0.1470	0.7863	1.3538
θ_{18}	10000	1.3243	0.2884	0.7711	1.8919
θ_{21}	10000	-0.8716	0.2808	-1.4102	-0.3199
θ_{22}	10000	-0.9585	0.1713	-1.2945	-0.6272
θ_{23}	10000	-0.8928	0.1290	-1.1492	-0.6454
θ_{24}	10000	-1.1375	0.1358	-1.4124	-0.8846
θ_{25}	10000	-1.6205	0.3399	-2.3011	-0.9646
θ_{26}	10000	-1.3484	0.1545	-1.6482	-1.0508
θ_{27}	10000	-1.5803	0.1547	-1.8828	-1.2863
θ_{28}	10000	-1.8926	0.3634	-2.5921	-1.1910
θ_{31}	10000	-0.9149	0.3135	-1.5162	-0.3013
θ_{32}	10000	-1.0263	0.1858	-1.3757	-0.6513
θ_{33}	10000	-1.0036	0.1379	-1.2698	-0.7282
θ_{34}	10000	-1.1290	0.1467	-1.4223	-0.8528
θ_{35}	10000	-1.8005	0.3749	-2.5164	-1.0523
θ_{36}	10000	-1.2928	0.1663	-1.6150	-0.9680
θ_{37}	10000	-1.6179	0.1676	-1.9590	-1.3022
θ_{38}	10000	-2.1258	0.3989	-2.9103	-1.3552

結果

- ・ 個人の属性で比較的に有意なものは見つからなかった
 - ・ 統計学的に差が有意とは言えない
- ・ ただ、投資目的に関しては、若干ばらつきがあった
 - ・ 一番文脈効果が発生しやすいのは「長期投資目的」
 - ・ 最下位は「企業の成長を応援する目的」

まとめ

- ・ 今回の結論
- 1. 金融商品の購買行動の中で文脈効果が発生する
 - ・ 投資金額が高い選択肢の方が、文脈効果が大きい
- 1. 投資家ごとに文脈効果の大きさが変化する
 - ・ 「金融資産」と「投資目的」のみでは文脈効果の影響を説明できない

まとめ

- ・ 考えられる施策

1. 選択肢の番号が低い部分に高い投資金額にあてる
投資家は高い金額の投資を選択する可能性が高い ⇒
2. 投資家が損失を被る恐れ
⇒政府によってこの事象を広く情報公開すべき

今後の課題と展望

- ・ コースの金額自体が文脈効果に与える影響
 - ・ コースの金額を変えた時に文脈効果は変化するのか
- ・ コースの数と文脈効果
 - ・ コース数が3つでないときに文脈効果は変化するのか
- ・ 一つの選択行動が次の選択行動に影響する状況
 - ・ 以前投資を行った投資家の選択行動並びに文脈効果は変化するのか

今後の課題と展望

- ・ 選択肢の組み合わせ
 - ・ 投資家が新たな選択肢を作っていた場合、文脈効果は変化するのか
- ・ 投資家・プロジェクトの具体的な属性
 - ・ 投資家やプロジェクトの具体的な属性で文脈効果を説明できるのか
- ・ 観測事象の一般化
 - ・ 「FUNDINNO」以外での文脈効果は変化するのか
- ・ 介入実験
 - ・ 金額や株数を変化することで文脈効果の影響は変化するのか