

比較型項目における 項目フォーマットと情報量の関係について

分寺 杏介¹ 岡田 謙介²

¹神戸大学 経営学研究科

²東京大学 教育学研究科



¹bunji@bear.kobe-u.ac.jp

Outline

1 Introduction

多肢選択のフォーマットの話

2 方法

分析モデル (Thurstonian IRT)

項目・テスト情報量

3 結果

テスト情報量の比較

単位時間あたりの比較

回答しやすさの評価

■ リッカート尺度

一つ一つの項目について「程度」を答える

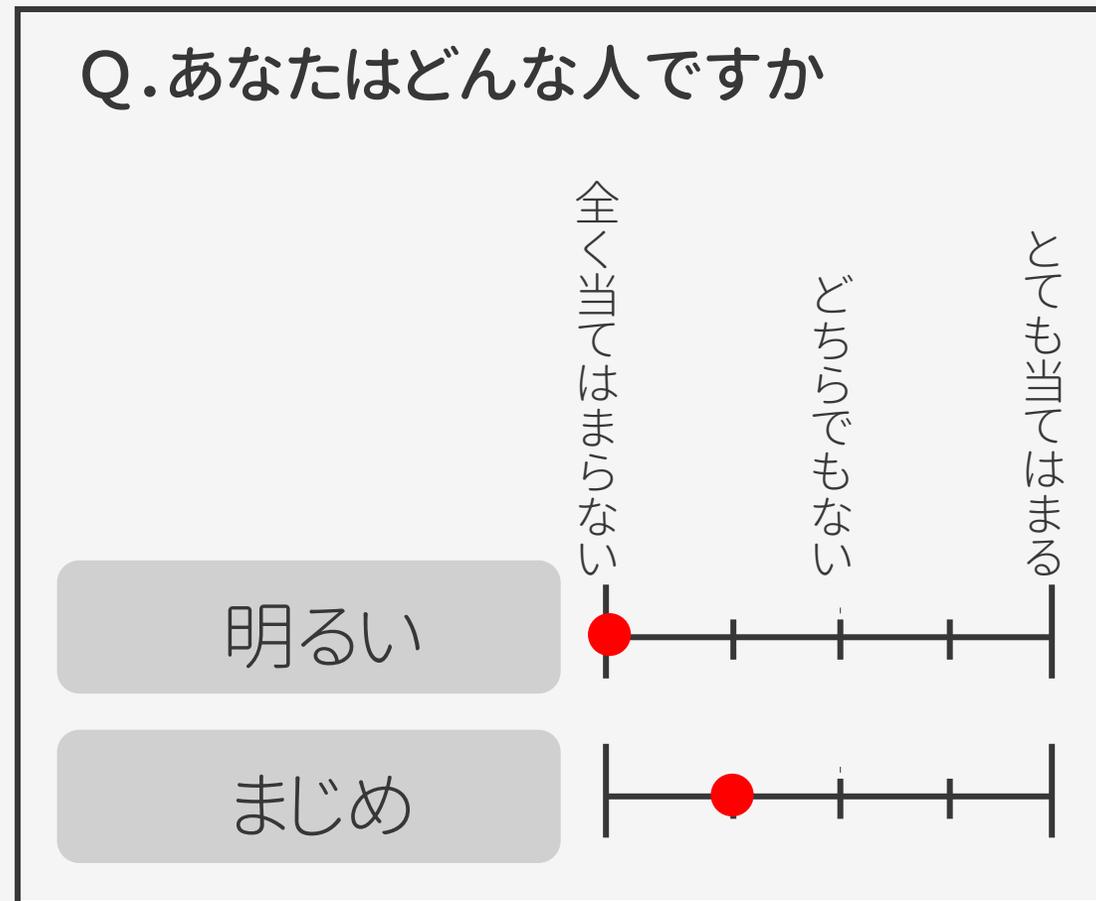
e.g., 自分に当てはまる程度, 賛成する程度

■ 系統的バイアスの影響を受けやすい

中心化傾向…5段階なら3を選びやすい

黙従傾向(寛大化傾向)…内容とは無関係に「あてはまる」を選びやすい

フェイキング…自分がよく見えるように意図的に回答を変える など



Single-Stimulus (SS); Likert scale

Q.どっちがより当てはまる?



明るい

まじめ

■ (多肢)強制選択式(Forced-Choice; FC)

複数の選択肢の中から回答する形式

- 最も当てはまる／らないもの
- 当てはまる順にランキング
- ▶ 中心化傾向などは起こり得ない
フェイキングもかなり抑えられる

Q.あなたはどんな人ですか

全く当てはまらない

どちらでもない

とても当てはまる

明るい

まじめ

Single-Stimulus (SS); Likert scale

FCのほうが妥当性が高いという先行研究あり (e.g., Christiansen et al., 2005, Salgado & Tauriz, 2014)

■ いくつかのフォーマットが考えられる

Q.どっちがより当てはまる?

明るい まじめ

■ 二択

答えやすい?

Q.どっちがどの程度当てはまる?

明るい まじめ

とても やや やや とても

■ 多肢選択

情報が多い?

Q.どっちがどの程度当てはまる?

明るい まじめ

■ スライダースケール

情報をもっと多い?

- 測定の目的は回答者の特性値を精度良く推定すること
情報量…特性値の推定に対してどの程度の情報を与えるか

- その観点で見ると...

Q.どっちがより当てはまる?

明るい

まじめ

カテゴリ数が多いほど
情報量が多い

Q.どっちがどの程度当てはまる?

明るい

まじめ

とても

やや

やや

とても



回答からは区別できない



ある程度区別できる!



■ カテゴリ数が多いと回答が難しくなる？

認知負荷が高くなるかもしれない

▶ 回答時間が長くなるとしたら、単位時間あたり情報量はどうなる？

リッカート尺度はVAS(スライダー)より回答しやすい(Dourado et al., 2021; van Laerhoven et al., 2004)

▶ 比較の場合も同じことが言えるか？

■ カテゴリ数が多いと正しく回答できないかも？

ノイズの影響で識別力が低下するならば情報量も下がる

リッカート尺度の場合カテゴリ数が多いほうが因子負荷は高くなる (Xu & Leung, 2018)

▶ 比較の場合も同じことが言えるか？

■ 強制選択のフォーマット

Q.どっちがより当てはまる?

明るい

まじめ

■ 二択

Q.どっちがどの程度当てはまる?

明るい

まじめ

とても

やや

やや

とても

■ 多肢選択

Q.どっちがどの程度当てはまる?

明るい

↓

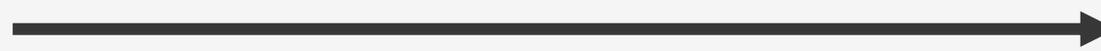
まじめ

■ スライダースケール

理論的には

情報量

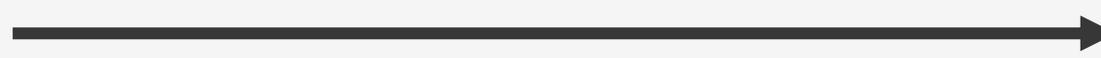
少ない



多い

答えやすさ

答えやすい?



答えにくい?

回答時間

短い?

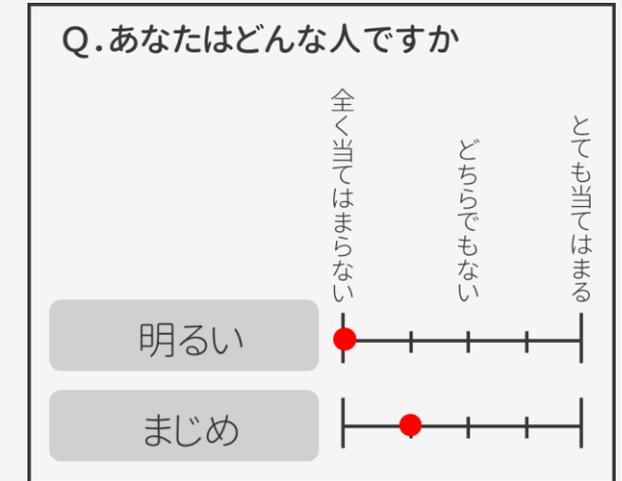


長い?

異なるフォーマットを比較する

二択・多肢選択・スライダーにリッカートを加えた4種類

- (項目・テスト)情報量
- 単位時間あたり情報量
- (主観的な)回答しやすさ



Outline

1 Introduction

多肢選択のフォーマットの話

2 モデル

分析モデル (Thurstonian IRT)

項目・テスト情報量

3 結果

テスト情報量の比較

単位時間あたりの比較

回答しやすさの評価

■ **Thurstonian IRTモデル** (Brown and Maydeu-Olivares, 2011)

二択

Q.どっちがより当てはまる?

0

明るい

$j^{(l)}$: 外向性

1

まじめ

$j^{(m)}$: 誠実性

μ : 選択肢の選好の平均
 β : 因子負荷
 η : 因子得点(特性値)

正規累積
モデル

ロジスティック
モデル

- 2つの文 ($j^{(l)}, j^{(m)}$)はそれぞれ異なる因子 ($d_j^{(l)}, d_j^{(m)}$) を測定する

$$X_{ij}^{(l-m)*} = u_{ij}^{(m)} - u_{ij}^{(l)} \quad X_{ij}^{(l-m)} = 1 \text{ if } X_{ij}^{(l-m)*} \geq 0$$

- 一方の潜在変数 $u_{ij}^{(m)}$ について見ると

$$u_{ij}^{(m)} = \mu_j^{(m)} + \beta_j^{(m)} \eta_{id_j^{(m)}} + \varepsilon_{ij}^{(m)} \quad \varepsilon_{ij}^{(m)} \sim N(0, \Psi_j^{(m)2})$$

- ($j^{(l)}, j^{(m)}$) 間の比較において選択肢 $j^{(m)}$ が選ばれる確率は

$$P(X_{ij}^{(l-m)} = 1 | \eta_i) = \Phi \left[\left(\mu_j^{(m)} - \mu_j^{(l)} \right) + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} \right]$$

$\Phi(\cdot)$ ▶ 標準正規分布の累積分布関数

または

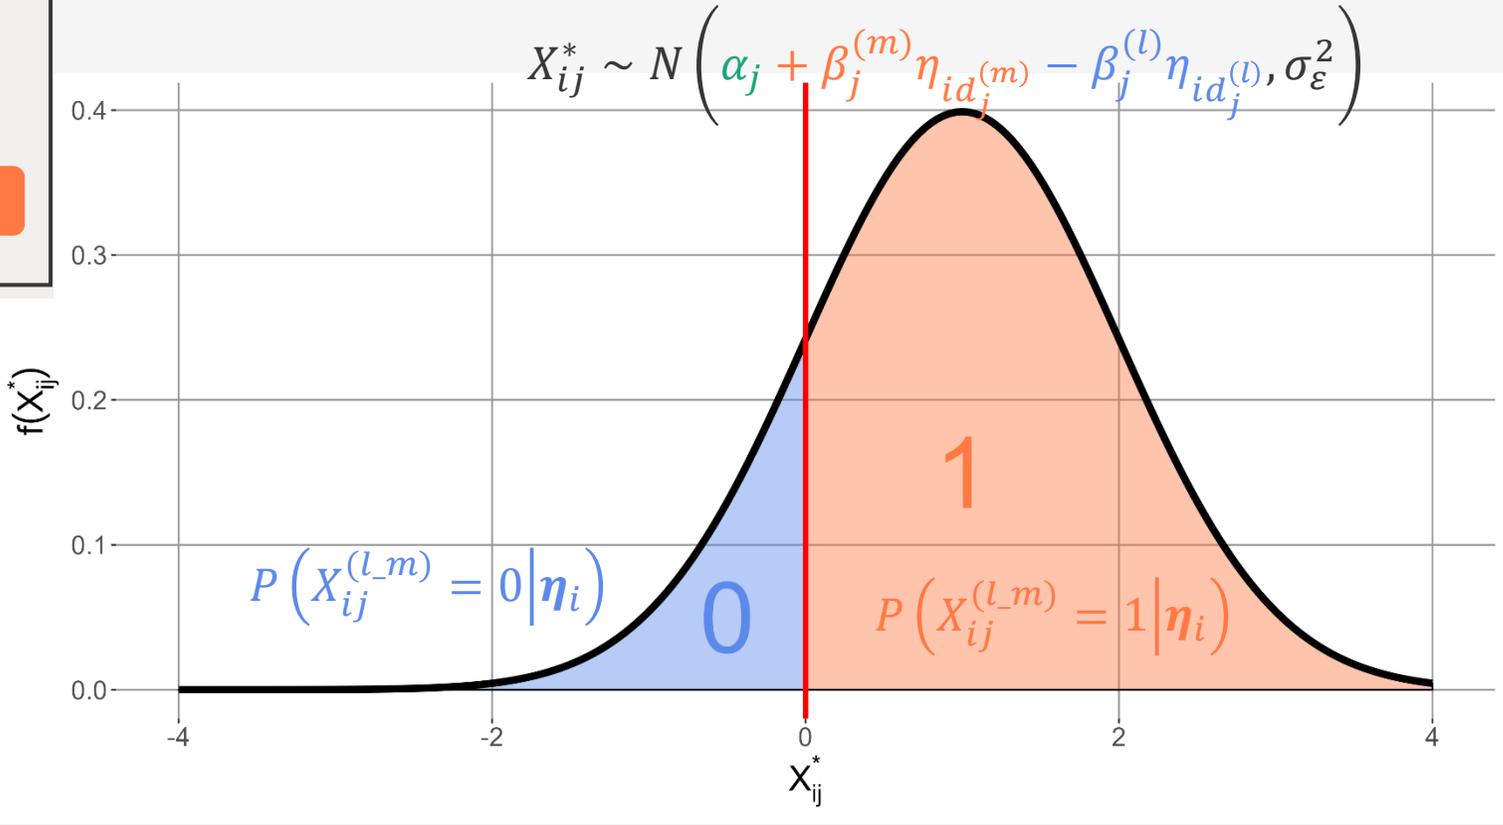
$$P(X_{ij}^{(l-m)} = 1 | \eta_i) = \left(1 - \exp \left[\left(\mu_j^{(m)} - \mu_j^{(l)} \right) + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} \right] \right)^{-1}$$

正規累積
モデル

$$P(X_{ij}^{(l,m)} = 1 | \eta_i) = \Phi \left[\underbrace{\left(\mu_j^{(m)} - \mu_j^{(l)} \right)}_{\alpha_j} + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} \right]$$

Q.どっちがより当てはまる?

0	1
明るい	まじめ
$j^{(l)}$: 外向性	$j^{(m)}$: 誠実性



$\mu_j^{(l)} + \beta_j^{(l)} \eta_{id_j^{(l)}}$
が大きい
↓
文 $j^{(l)}$ が
選ばれやすい

$\mu_j^{(m)} + \beta_j^{(m)} \eta_{id_j^{(m)}}$
が大きい
↓
文 $j^{(m)}$ が
選ばれやすい

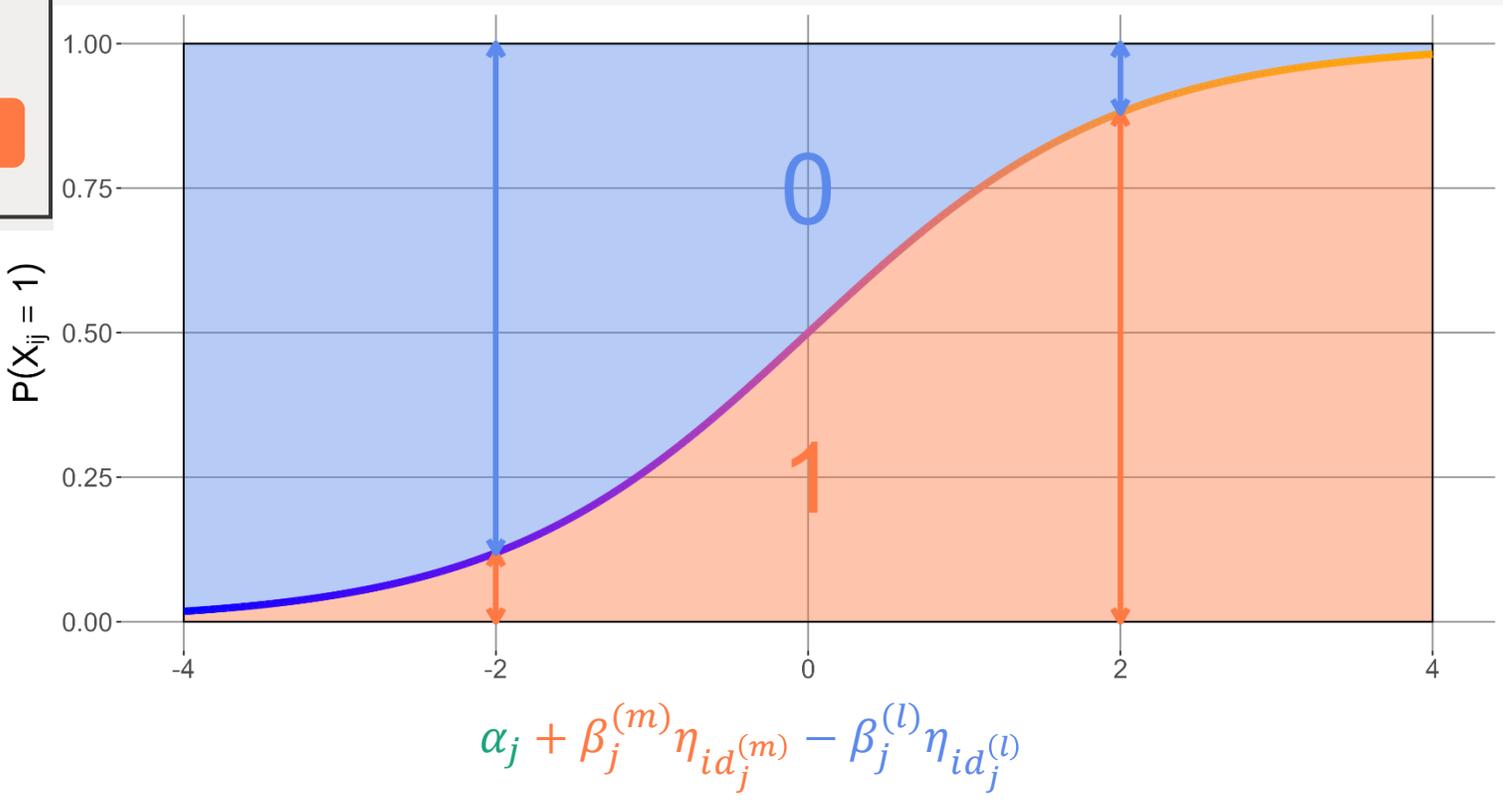
$$X_{ij}^* = \alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} + (\varepsilon_{ij}^{(l)} - \varepsilon_{ij}^{(m)})$$

正規累積
モデル

$$P(X_{ij}^{(l,m)} = 1 | \eta_i) = \Phi \left[\underbrace{(\mu_j^{(m)} - \mu_j^{(l)})}_{\alpha_j} + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} \right]$$

Q.どっちがより当てはまる?

0	1
明るい	まじめ
$j^{(l)}$: 外向性	$j^{(m)}$: 誠実性



$\mu_j^{(l)} + \beta_j^{(l)} \eta_{id_j^{(l)}}$
が大きい
↓
文 $j^{(l)}$ が
選ばれやすい

$\mu_j^{(m)} + \beta_j^{(m)} \eta_{id_j^{(m)}}$
が大きい
↓
文 $j^{(m)}$ が
選ばれやすい

TIRTの拡張 (Brown and Maydeu-Olivares, 2018)

多肢選択

Q.どっちがどの程度当てはまる?

明るい

まじめ

0 1 2 3

とても やや やや とても

$j^{(l)}$: 外向性 誠実性: $j^{(m)}$

α : 選好の平均の差
 β : 因子負荷
 η : 因子得点 (特性値)

正規累積
モデル

- 2つの文 ($j^{(l)}, j^{(m)}$) はそれぞれ異なる因子 ($d_j^{(l)}, d_j^{(m)}$) を測定する

$$X_{ij}^{(l-m)*} = u_{ij}^{(l)} - u_{ij}^{(m)} \quad X_{ij}^{(l-m)} = \begin{cases} C-1 & \text{if } X_{ij}^{(l-m)*} \geq \tau_{C-1} \\ C-2 & \text{if } \tau_{C-1} \geq X_{ij}^{(l-m)*} \geq \tau_2 \\ \dots & \\ 1 & \text{if } \tau_2 \geq X_{ij}^{(l-m)*} \geq \tau_1 \\ 0 & \text{if } X_{ij}^{(l-m)*} \leq \tau_1 \end{cases}$$

- あとはTIRTと同じ
- $(j^{(l)}, j^{(m)})$ 間の比較において選択肢 c が選ばれる確率は

$$P(X_{ij}^{(l-m)} \geq c | \eta_i) = \Phi \left[\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} - \tau_c \right]$$

$$P(X_{ij}^{(l-m)} = c | \eta_i) = P(X_{ij}^{(l-m)} \geq c | \eta_i) - P(X_{ij}^{(l-m)} \geq c + 1 | \eta_i)$$

正規累積
モデル

Q.どっちがどの程度当てはまる?

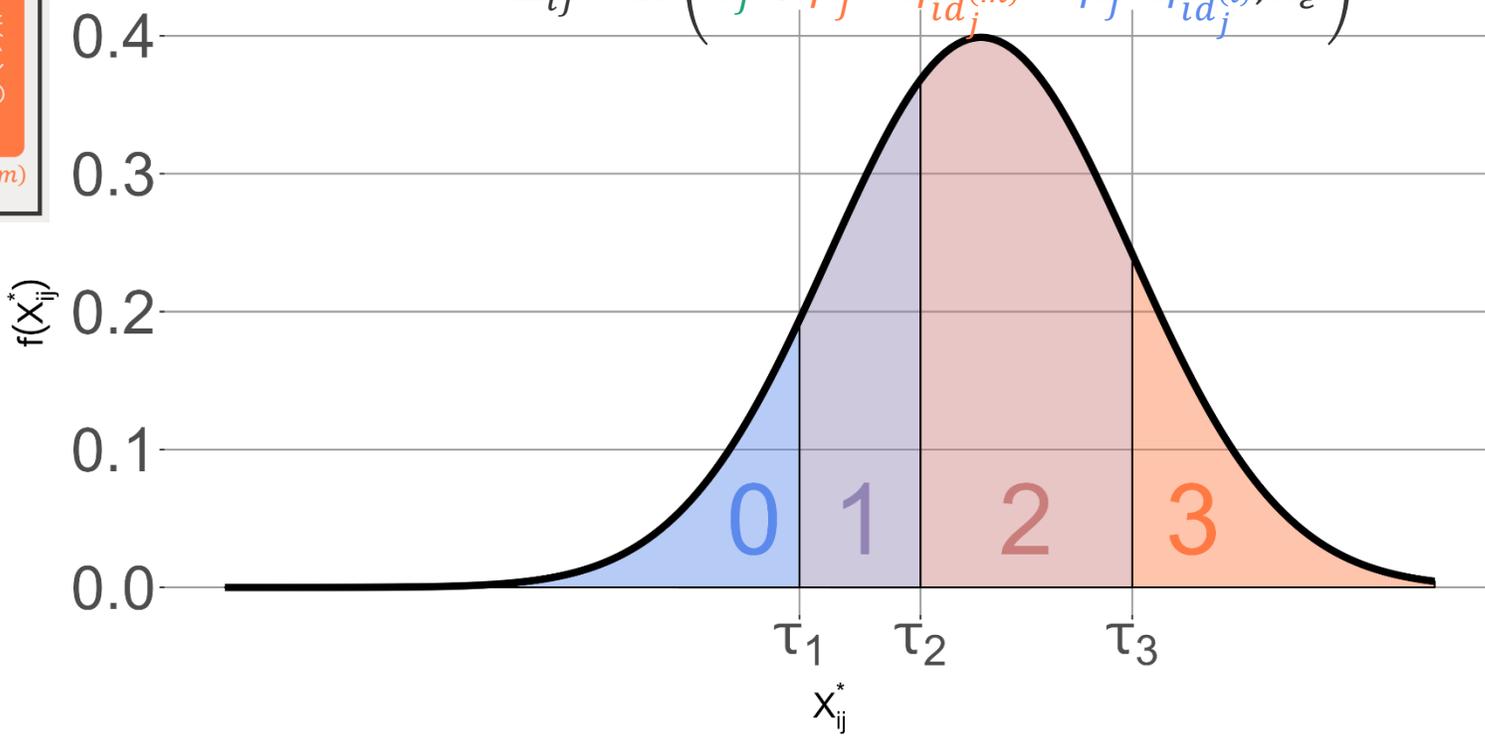
明るい	0	1	2	3	まじめ
	とても	やや	やや	とても	

$j^{(l)}$: 外向性 誠実性: $j^{(m)}$

$$P(X_{ij}^{(l-m)} \geq c | \boldsymbol{\eta}_i) = \Phi \left[\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} - \tau_c \right]$$

$$P(X_{ij}^{(l-m)} = c | \boldsymbol{\eta}_i) = P(X_{ij}^{(l-m)} \geq c | \boldsymbol{\eta}_i) - P(X_{ij}^{(l-m)} \geq c + 1 | \boldsymbol{\eta}_i)$$

$$X_{ij}^* \sim N \left(\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}}, \sigma_\varepsilon^2 \right)$$



$\mu_j^{(l)} + \beta_j^{(l)} \eta_{id_j^{(l)}}$
が大きい
↓
文 $j^{(l)}$ が強く
選ばれやすい

$\mu_j^{(m)} + \beta_j^{(m)} \eta_{id_j^{(m)}}$
が大きい
↓
文 $j^{(m)}$ が強く
選ばれやすい

$$X_{ij}^* = \alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} + (\varepsilon_{ij}^{(l)} - \varepsilon_{ij}^{(m)})$$

正規累積
モデル

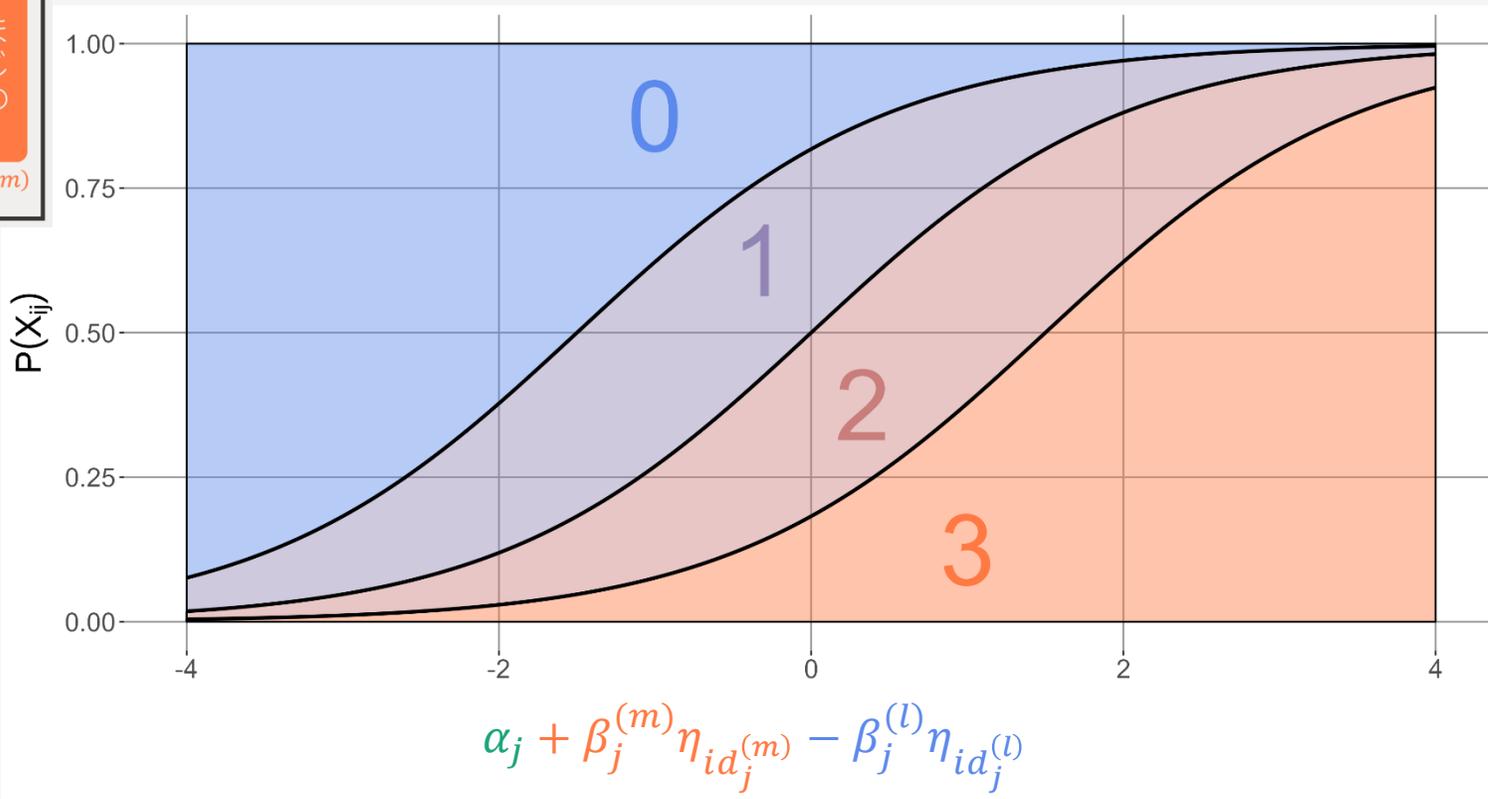
Q.どっちがどの程度当てはまる?

明るい	0	1	2	3	まじめ
	とても	やや	やや	とても	

$j^{(l)}$: 外向性 誠実性: $j^{(m)}$

$$P(X_{ij}^{(l-m)} \geq c | \boldsymbol{\eta}_i) = \Phi \left[\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} - \tau_c \right]$$

$$P(X_{ij}^{(l-m)} = c | \boldsymbol{\eta}_i) = P(X_{ij}^{(l-m)} \geq c | \boldsymbol{\eta}_i) - P(X_{ij}^{(l-m)} \geq c + 1 | \boldsymbol{\eta}_i)$$



$\mu_j^{(l)} + \beta_j^{(l)} \eta_{id_j^{(l)}}$
 が大きい
 ↓
 文 $j^{(l)}$ が強く
 選ばれやすい

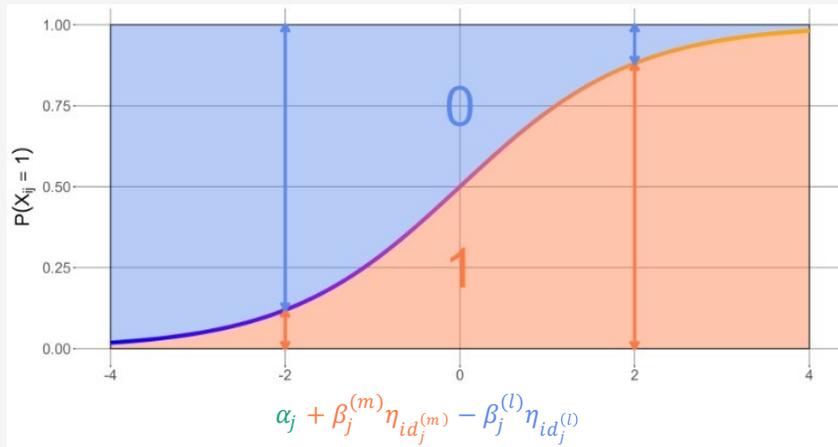
$\mu_j^{(m)} + \beta_j^{(m)} \eta_{id_j^{(m)}}$
 が大きい
 ↓
 文 $j^{(m)}$ が強く
 選ばれやすい

二値

2パラメータ
正規累積モデル

$$P(X_{ij} = 1|\eta_i) = \Phi[a_j(\eta_i - b_j)]$$

$$P(X_{ij}^{(l,m)} = 1|\eta_i) = \Phi\left[\alpha_j + \beta_j^{(m)}\eta_{id_j^{(m)}} - \beta_j^{(l)}\eta_{id_j^{(l)}}\right]$$



多値

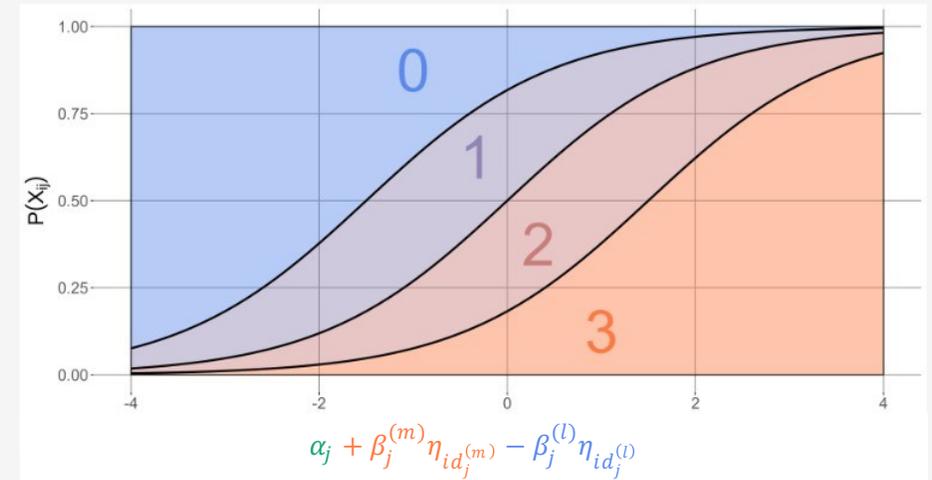
段階反応モデル

$$P(X_{ij} \geq c|\eta_i) = \Phi[a_j(\eta_i - b_j) - \tau_c]$$

$$P(X_{ij} = c|\eta_i) = P(X_{ij} \geq c|\eta_i) - P(X_{ij} \geq c + 1|\eta_i)$$

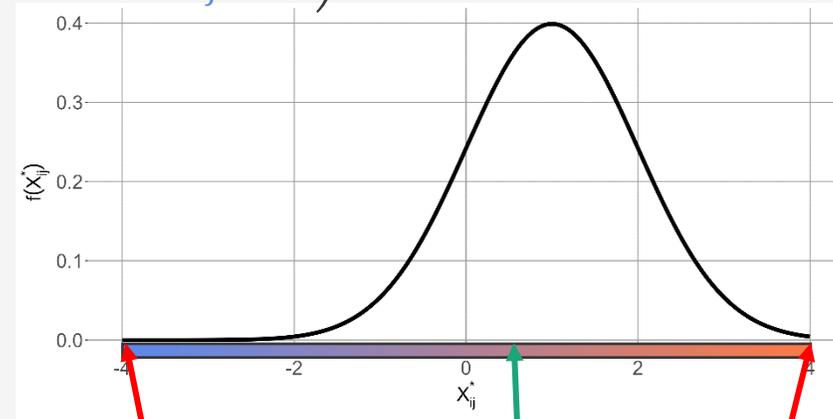
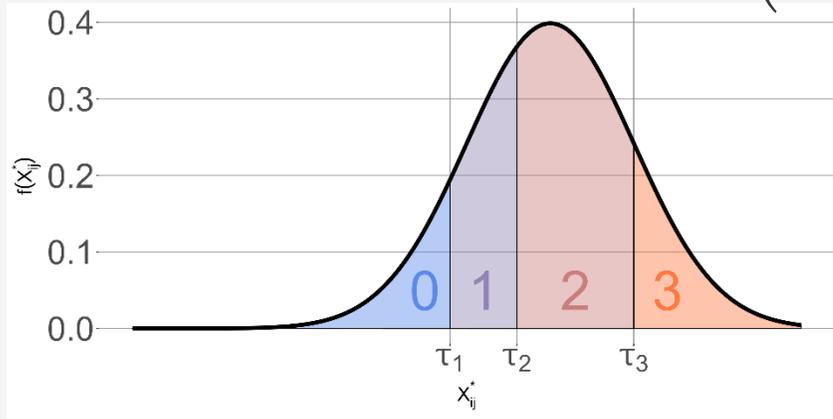
$$P(X_{ij}^{(l,m)} \geq c|\eta_i) = \Phi\left[\alpha_j + \beta_j^{(m)}\eta_{id_j^{(m)}} - \beta_j^{(l)}\eta_{id_j^{(l)}} - \tau_c\right]$$

$$P(X_{ij}^{(l,m)} = c|\eta_i) = P(X_{ij}^{(l,m)} \geq c|\eta_i) - P(X_{ij}^{(l,m)} \geq c + 1|\eta_i)$$



■ 本来観測したいのはカテゴリではなくその背後の連続量

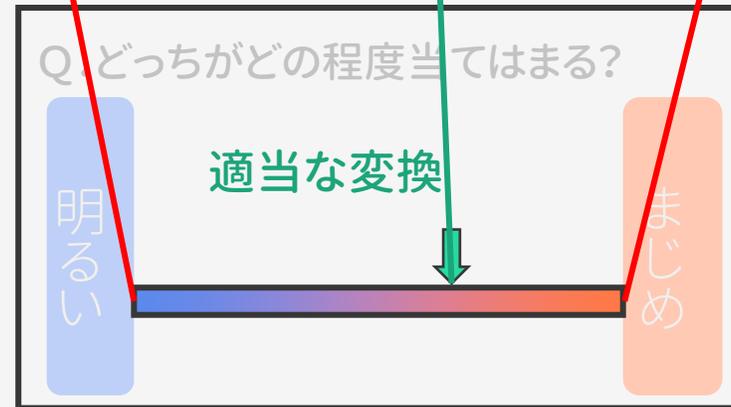
$$X_{ij}^* \sim N \left(\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}}, \sigma_\varepsilon^2 \right)$$



このまま
考えてみる

$$P(X_{ij}^* = z | \eta_i) = \frac{1}{\sqrt{2\pi\gamma_j^2}} \exp \left(-\frac{\left(\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} - z \right)^2}{2\gamma_j^2} \right)$$

平均 $\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}}$, 分散 γ_j^2 の
正規分布の確率密度



平均 $\alpha_j + \beta_j^{(m)}\eta_{id_j^{(m)}} - \beta_j^{(l)}\eta_{id_j^{(l)}}$, 分散 γ^2 の
正規分布の確率密度

選好の差によって潜在変数の分布が動く

$$X_{ij}^* \sim N\left(\alpha_j + \beta_j^{(m)}\eta_{id_j^{(m)}} - \beta_j^{(l)}\eta_{id_j^{(l)}}, \gamma^2\right)$$

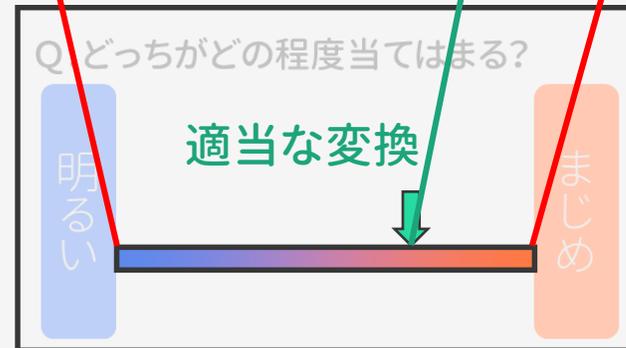
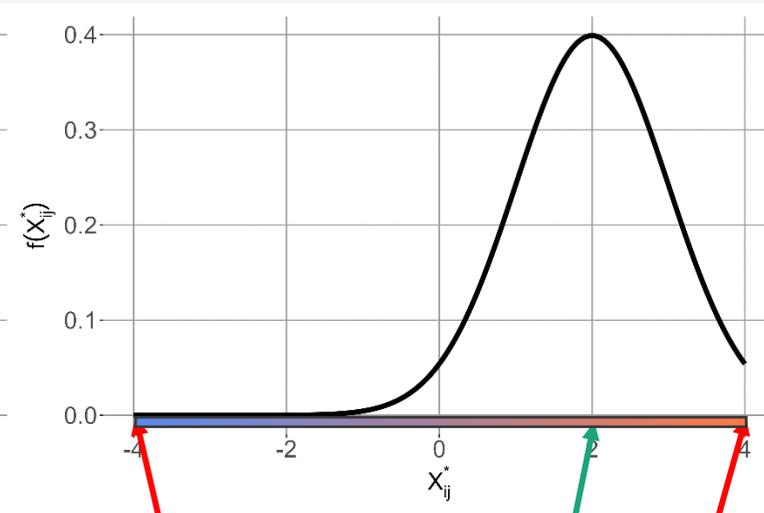
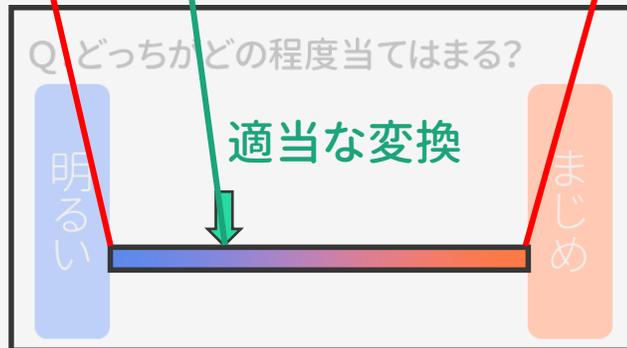
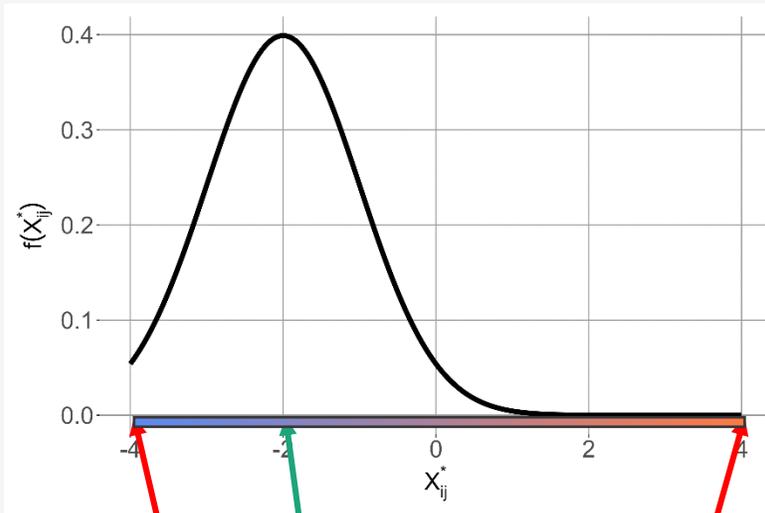
$\mu_j^{(l)} + \beta_j^{(l)}\eta_{id_j^{(l)}}$
が大きい



正規分布の
平均が小さい



文 $j^{(l)}$ が強く
選ばれやすい



$\mu_j^{(m)} + \beta_j^{(m)}\eta_{id_j^{(m)}}$
が大きい



正規分布の
平均が大きい



文 $j^{(m)}$ が強く
選ばれやすい

■ 測定の目的は回答者の特性値を精度良く推定すること

η_i

■ 項目への回答が特性値推定にもたらす情報は？

① 二値の場合

Q.どっちがより当てはまる？

0	1
明るい	まじめ
$j^{(l)}$: 外向性	$j^{(m)}$: 誠実性

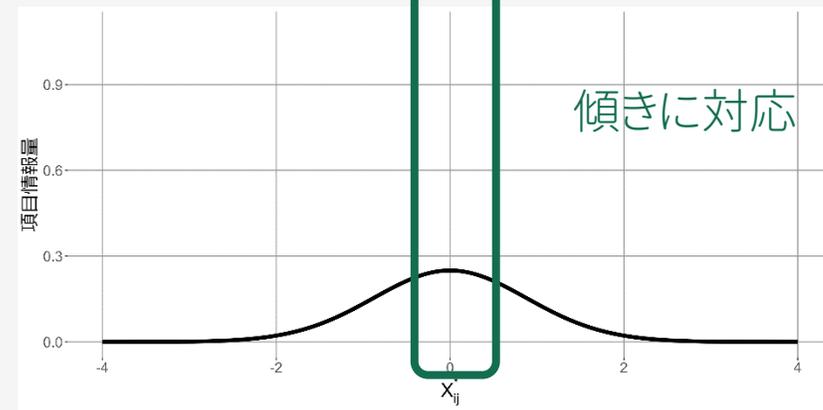
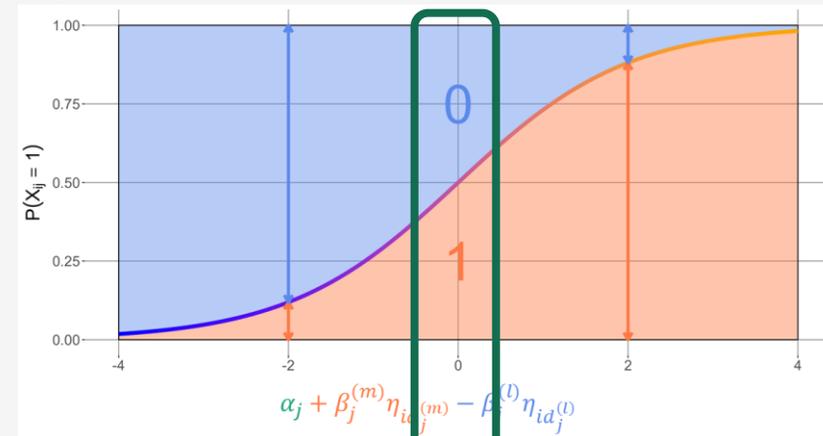
明るい > まじめ

外向性のほうが高い

でもどの程度かはわからない



選好の差が小さくなるような η_i の値なら
情報量が多い項目



■ 測定の目的は回答者の特性値を精度良く推定すること

η_i

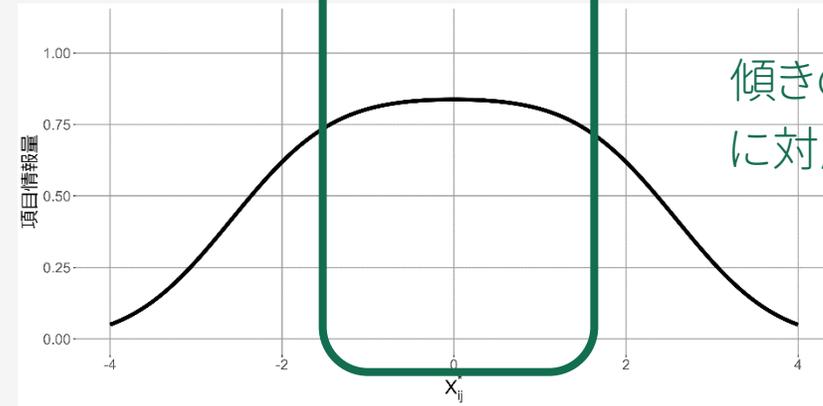
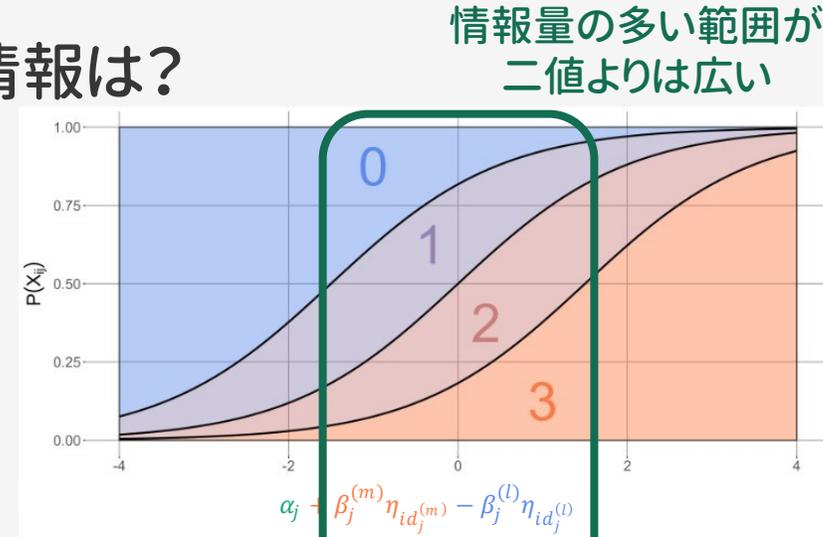
■ 項目への回答が特性値推定にもたらす情報は？

② 多値の場合



外向性のほうが高い

二値よりは多少程度がわかる

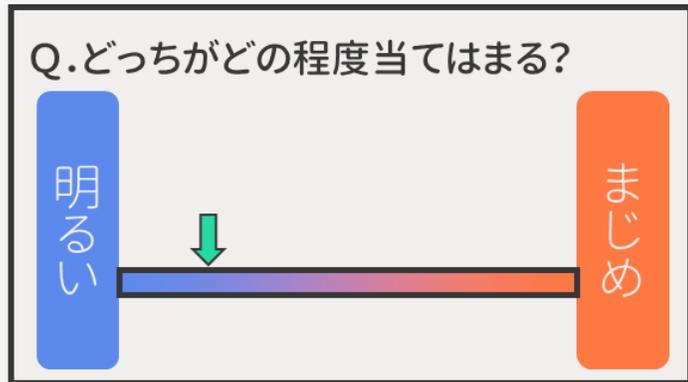


- 測定の目的は回答者の特性値を精度良く推定すること

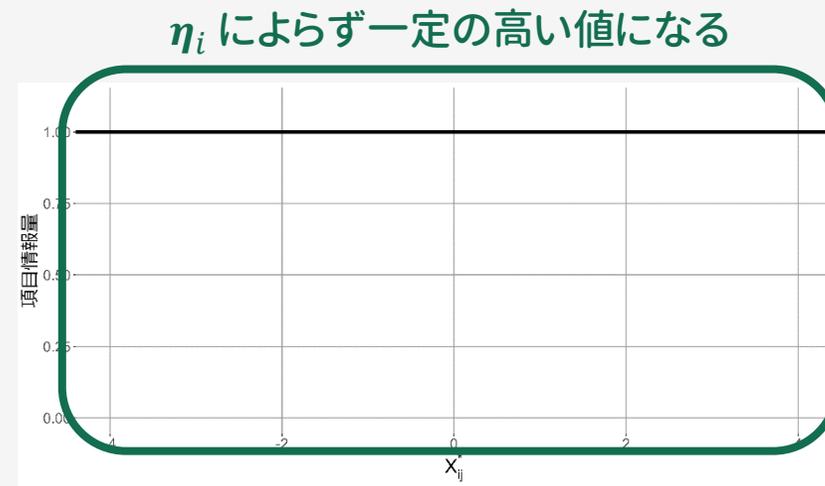
η_i

- 項目への回答が特性値推定にもたらす情報は？

③ 連続の場合



理論上はどこに回答しても
それが程度を明示している



- 測定の目的は回答者の特性値を精度良く推定すること

↓
 η_i

- 項目情報量=フィッシャー情報量

▶ 対数尤度の η_i に関する二階微分の期待値のマイナス

多次元なら
フィッシャー情報行列

$$I_j(\eta) = -E \left[\frac{\partial^2}{\partial \eta \partial \eta^\top} \ln P(X_{ij} | \eta_i) \right]$$

- テスト全体での情報量は単純に和を取れば良い

$$I(\eta) = \sum I_j(\eta)$$

- すると推定精度が求められる

最尤推定値の共分散行列が $I(\eta)^{-1}$ ➡

項目情報量が多いほうが嬉しい

■ 具体的な項目情報量の式は

$$I_j(\eta) = \beta_j^2 \sum_{c=1}^{C-1} \frac{[P'(X_{ij} \geq c|\eta_i) - P'(X_{ij} \geq c-1|\eta_i)]^2}{P(X_{ij} \geq c|\eta_i) - P(X_{ij} \geq c-1|\eta_i)}$$

因子負荷量 × sum(カテゴリごとの情報量)

またの名を **項目識別力**

$P'(X_{ij} \geq c|\eta_i)$ は $P(X_{ij} \geq c|\eta_i)$ の導関数
 ▶ 正規累積モデルの場合
 $\phi(X_{ij} = c|\eta_i)$

■ 本来特性値は連続量

▶ **カテゴリ化することで情報量が減少してしまう**

情報量の減少の程度は(Bürkner, 2022)

$$0 \leq \sum_{c=1}^{C-1} \frac{[P'(X_{ij} \geq c|\eta_i) - P'(X_{ij} \geq c-1|\eta_i)]^2}{P(X_{ij} \geq c|\eta_i) - P(X_{ij} \geq c-1|\eta_i)} \leq 1 \quad \blacktriangleright$$

- カテゴリ数が少ないほど小さくなる
- カテゴリ数が無限のとき
 $(X_{ij}^{(l,m)*}$ が直接測定できるとき)に1になる
- ▶ 連続反応の場合 $I_j(\eta) = \beta_j^2$

Q.どっちがどの程度当てはまる?

明るい	3	2	1	0	まじめ
	とても	やや	やや	とても	

$j^{(l)}$: 外向性 誠実性: $j^{(m)}$

■ 段階反応モデルにおける項目情報量

各文が測定している因子に対応したベクトル β_j を用意する

例 | 3因子を測定する尺度において文*l*が因子1, 文*m*が因子3を測定している場合

$$\beta_j = [\beta_j^{(l)} \quad 0 \quad -\beta_j^{(m)}]$$

後はおなじ $I_j(\eta) = \beta_j^T \beta_j \sum_{c=1}^{c-1} \frac{[P'(X_{ij} \geq c | \eta_i) - P'(X_{ij} \geq c - 1 | \eta_i)]^2}{P(X_{ij} \geq c | \eta_i) - P(X_{ij} \geq c - 1 | \eta_i)}$

$$= \begin{bmatrix} \beta_j^{(l)2} & 0 & -\beta_j^{(l)} \beta_j^{(m)} \\ 0 & 0 & 0 \\ -\beta_j^{(l)} \beta_j^{(m)} & 0 & \beta_j^{(m)2} \end{bmatrix} \sum_{c=1}^{c-1} \frac{[P'(X_{ij} \geq c | \eta_i) - P'(X_{ij} \geq c - 1 | \eta_i)]^2}{P(X_{ij} \geq c | \eta_i) - P(X_{ij} \geq c - 1 | \eta_i)}$$

参加者

クラウドソーシングで募集した日本人500名(18歳以上)

使用した項目

Big-Five factor marker questionnaire (Apple & Neff, 2012)

5因子×各10文=計50文

▶ 因子のペアのバランスを取るように25ペアを構成

	A	B
1	すぐにストレスがたまってしまう	おしゃべりではない
2	他人を気づかうことはない	語彙が豊富である
3	いつもリラックスしていることが多い	想像力が豊かである
4	心配性である	持ち物が整理できないほうだ
5	いつも用意周到である	素晴らしいアイデアを持っている
6	動揺しやすい	盛り上げ役である
7	人を馬鹿にするほうだ	抽象的な考えを理解するのが苦手だ
8	慌てやすい	抽象的な考えには興味がない
9	引っ込み思案である	細かいことに気がつく
10	あまり話すことがない	ものわかりが良いほうだ
11	気分をコロコロ変える	すぐに雑用を済ませる
12	他人に興味がある	整頓するのが好きである
13	気分が著しく変化するほうだ	他の人のために時間を割くほうだ
14	人前でもあがらない	人に共感しやすい
15	無茶なことをする	難しい言葉を使うほうだ
16	落ち込むことはめったにない	自分から話しかけるほうである
17	他人の問題には興味がない	予定に従うほうだ
18	人から注目を浴びるのは好きではない	整理整頓を怠りがち
19	パーティでは色々な人と話すほうだ	優しい心を持っている
20	仕事や学習をさぼることが多い	アイデアが乏しいほうだ
21	イライラしやすい	他人にはまったく興味がない
22	他の人の気持ちがわかる	張り切って仕事や学習に取り組むほうだ
23	落ち込むことが多い	いろんなことを反省しては時間を過ごす
24	人見知りする	人を安心させる
25	注目的になるのは嫌ではない	アイデアが豊富である

回答フォーマット ▶ 全てクリック1回で回答

二択

どちらの方が、より強く当てはまりますか

静かな方がいい

悩みだすと止まらない

強く当てはまる

強く当てはまる

リッカート

以下の文は、あなたにどの程度当てはまりますか

静かな方がいい

全く
当てはまらない

当てはまらない

あまり
当てはまらない

やや
当てはまる

当てはまる

非常に
当てはまる

多肢選択

どちらの方が、どの程度強く当てはまりますか

静かな方がいい

悩みだすと止まらない

非常に

とても

やや

やや

とても

非常に

スライダー

どちらの方が、どの程度強く当てはまりますか

静かな方がいい

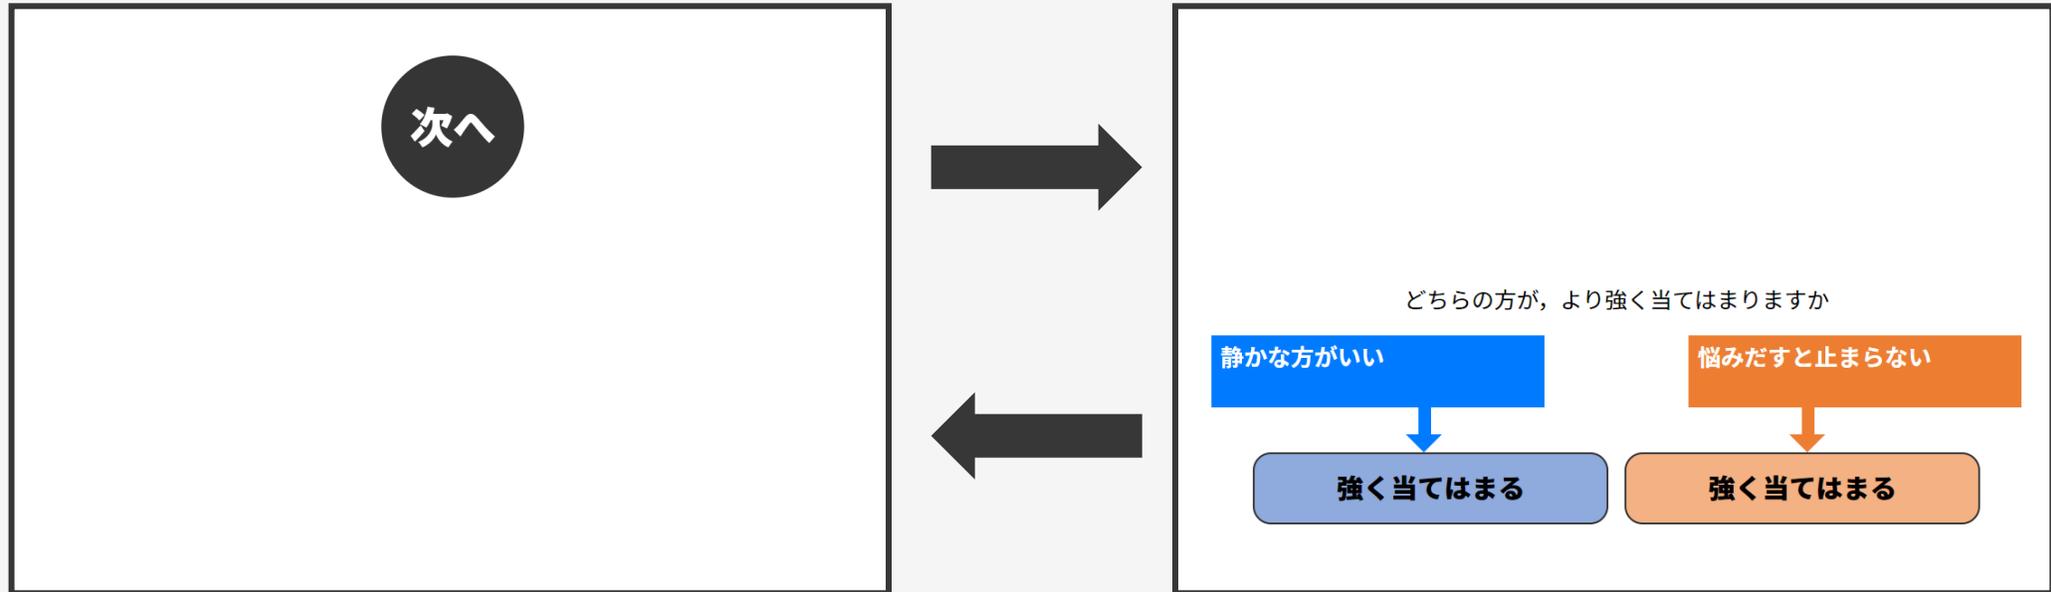
悩みだすと止まらない

非常に

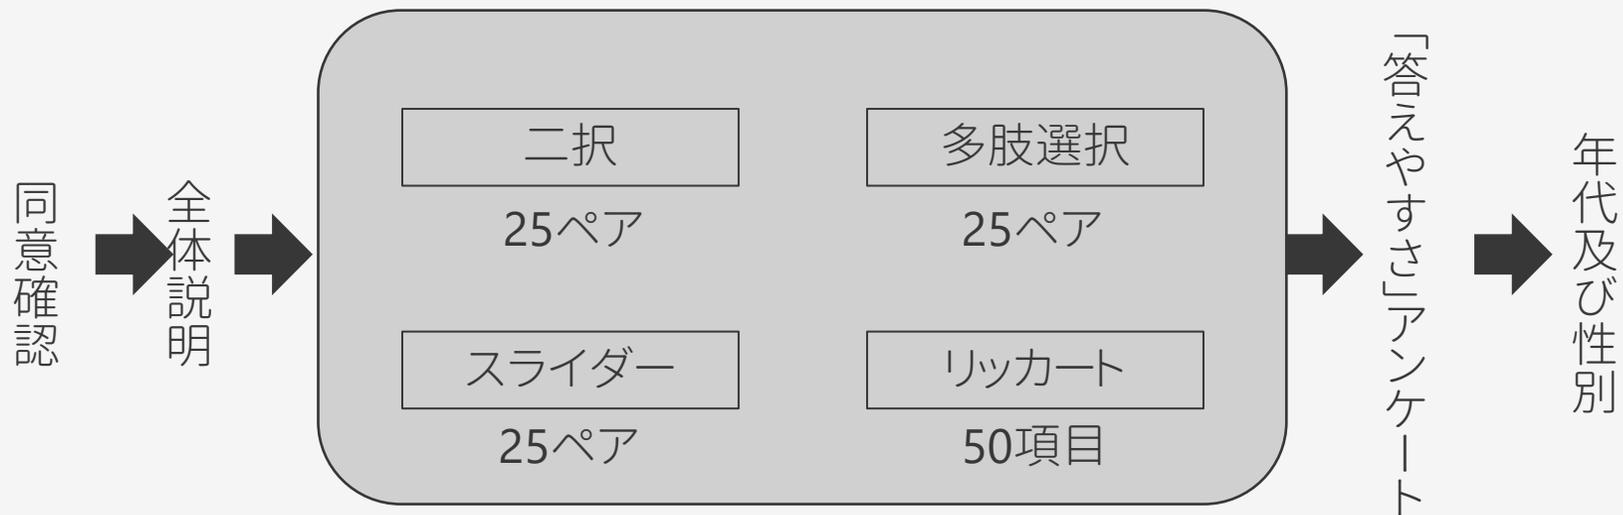
どちらともいえない

非常に

- 各項目の間に注視点のようなものを用意
マウスカーソルを乗せると次の項目が出てくる



全てのフォーマットで **次へ** から回答ボタンの垂直距離は統一
▶ 回答のために動かすマウスカーソルの距離を統制する



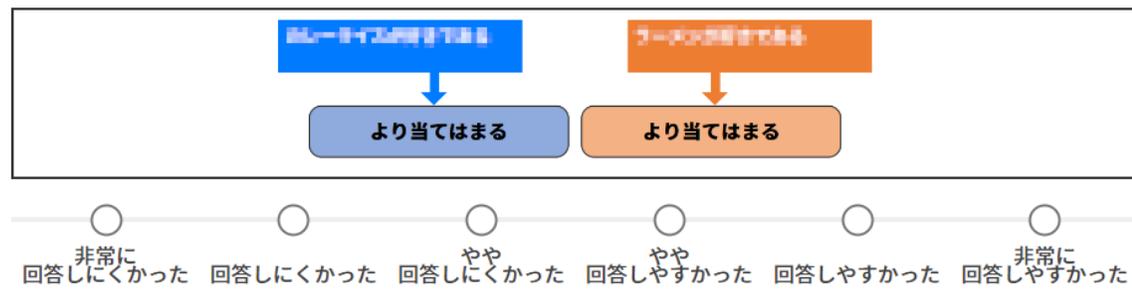
■ 実施順はランダム

フォーマットの実施順, フォーマット内での提示順, ペア内の左右の配置

■ 「答えやすさ」アンケート

6件法

最後に、本実験で使用した4種類の回答形式について、どの程度回答しやすかったかを6段階で評価してください。



1 二択・多肢選択

正規累積
TIRTモデル

$$\alpha_j = \mu_j^{(m)} - \mu_j^{(l)}$$

$$P(X_{ij}^{(l-m)} \geq c | \eta_i) = \Phi \left[\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} - \tau_c \right]$$

$$P(X_{ij}^{(l-m)} = c | \eta_i) = P(X_{ij}^{(l-m)} \geq c | \eta_i) - P(X_{ij}^{(l-m)} \geq c + 1 | \eta_i)$$

2 リッカート

正規累積
段階反応モデル

$$P(X_{ij} \geq c | \eta_i) = \left(1 - \Phi \left[\beta_j (\eta_{id_j} - \alpha_j - \tau_c) \right] \right)^{-1}$$

$$P(X_{ij} = c | \eta_i) = P(X_{ij} \geq c | \eta_i) - P(X_{ij} \geq c + 1 | \eta_i)$$

3 スライダー

連続反応モデル

$$X_{ij}^* = \log \left(\frac{X_{ij}}{1 - X_{ij}} \right) \leftarrow \text{適当な変換}$$

Samejima, 1973

$$P(X_{ij}^* = z | \eta_i) = \frac{1}{\sqrt{2\pi\gamma_j^2}} \exp \left(- \frac{\left(\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} - z \right)^2}{2\gamma_j^2} \right)$$

$$I_j(\eta) = \text{因子負荷量} \times \text{sum(カテゴリごとの情報量)}$$

テスト情報量は総和+事前分布の情報量

$$I(\eta) = \sum I_j(\eta) + I_\Sigma$$

1 二択・多肢選択

ロジスティック
TIRTモデル

$$I_j(\eta) = \beta_j^T \beta_j \sum_{c=1}^{C-1} \frac{[p'(X_{ij} \geq c|\eta_i) - p'(X_{ij} \geq c-1|\eta_i)]^2}{P(X_{ij} \geq c|\eta_i) - P(X_{ij} \geq c-1|\eta_i)}$$

2 リッカート

ロジスティック
段階反応モデル

$$I_j(\eta) = \beta_j^2 \sum_{c=1}^{C-1} \frac{[p'(X_{ij} \geq c|\eta_i) - p'(X_{ij} \geq c-1|\eta_i)]^2}{P(X_{ij} \geq c|\eta_i) - P(X_{ij} \geq c-1|\eta_i)} \rightarrow I_j(\eta) = \begin{bmatrix} I_j(\eta) & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}$$

3 スライダー

連続反応モデル

$$I_j(\eta) = \beta_j^T \beta_j$$

Samejima, 1973

テスト情報量の比較

分散共分散行列 $\mathbf{I}(\boldsymbol{\eta})^{-1}$ の対角成分 = 推定値の分散を見る

因子単位での情報量 → 推定精度

情報行列の行列式 $\det(\mathbf{I}(\boldsymbol{\eta}))$ を計算する (D-optimality)

5因子全てまとめたの情報量

単位時間あたりテスト情報量の比較

$\det(\mathbf{I}(\boldsymbol{\eta}))$ を合計回答時間 T_{sec} (単位: 秒) で割った値 $\frac{\det(\mathbf{I}(\boldsymbol{\eta}))}{T_{\text{sec}}}$

5因子全てまとめて

分散共分散行列 $\mathbf{I}(\boldsymbol{\eta})^{-1}$ の対角成分を T_{sec} 倍する $\left[\frac{1}{T_{\text{sec}}} \mathbf{I}(\boldsymbol{\eta}) \right]^{-1} = T_{\text{sec}} \mathbf{I}(\boldsymbol{\eta})^{-1}$

因子単位

回答しやすさ

対応のある一要因分散分析

■ 同じ意味のパラメータはモデル間で同じ事前分布を置く

$$\alpha_j \sim \text{Normal}(0,5)$$

$$\beta_j \sim \text{student_t}(4,0,2.5)$$

$$\boldsymbol{\eta}_i \sim \text{MVN}(0, \boldsymbol{\Sigma})$$

$$\boldsymbol{\Sigma} \sim \text{LKJ}(1)$$

$$\gamma_j \sim \text{Normal}(0,5)$$

$$P(X_{ij}^* = z | \boldsymbol{\eta}_i) = \frac{1}{\sqrt{2\pi\gamma_j^2}} \exp\left(-\frac{\left(\alpha_j + \beta_j^{(m)} \eta_{id_j^{(m)}} - \beta_j^{(l)} \eta_{id_j^{(l)}} - z\right)^2}{2\gamma_j^2}\right)$$

■ MCMCの設定

`chains=4`, `n_warmup=150`, `n_sampling=500` (収束は問題なし)

Outline

1 Introduction

多肢選択のフォーマットの話

2 モデル

分析モデル (Thurstonian IRT)

項目・テスト情報量

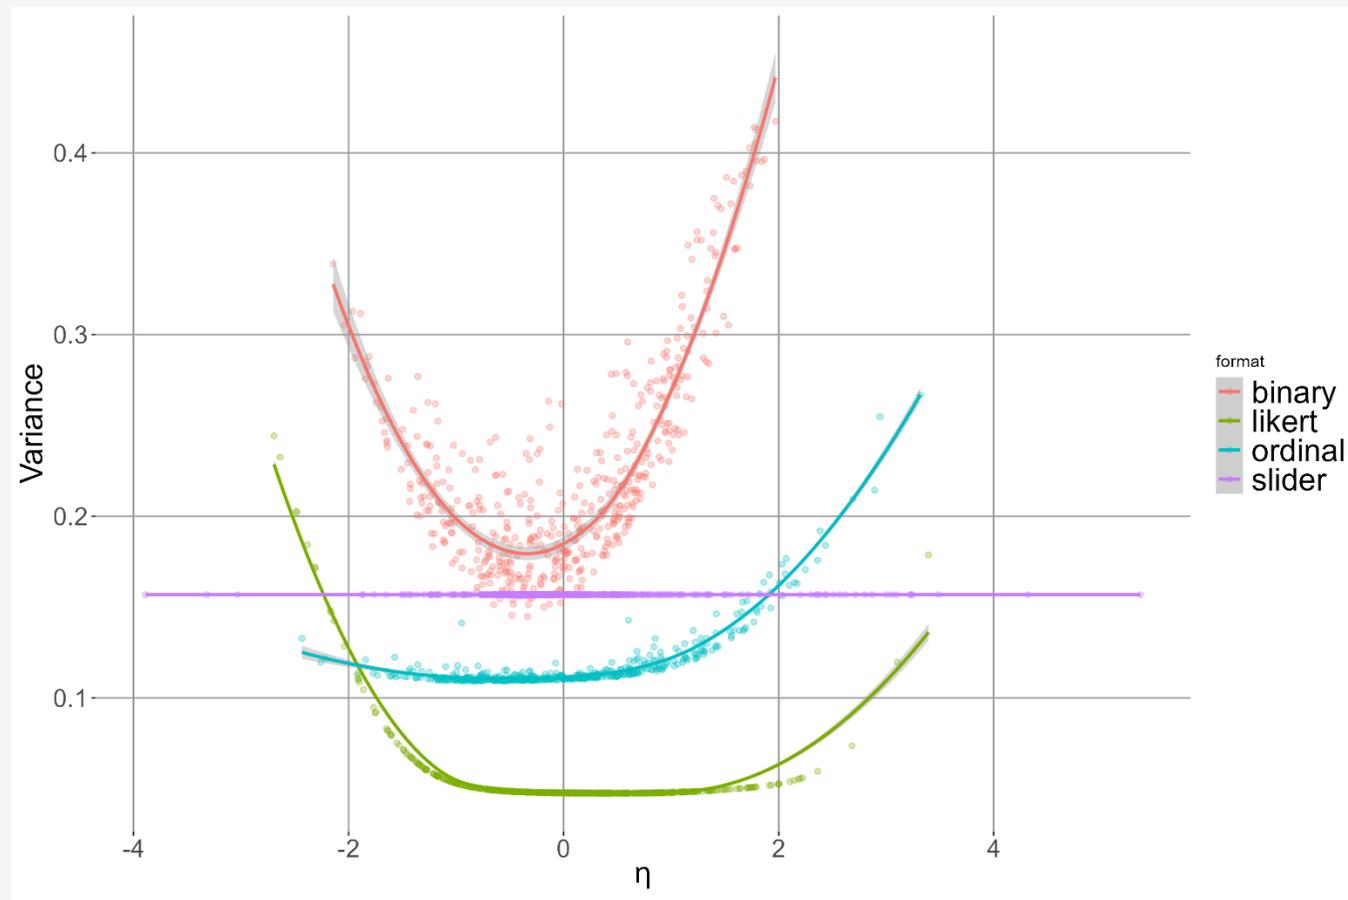
3 結果

テスト情報量の比較

単位時間あたりの比較

回答しやすさの評価

■ 分散共分散行列 $I_j(\eta)^{-1}$ の(1,1)成分=因子1の分散のプロット



【前提】

どのフォーマットも各因子は
10項目に出現する

▶ 項目辺り情報量を比べても同じ結果

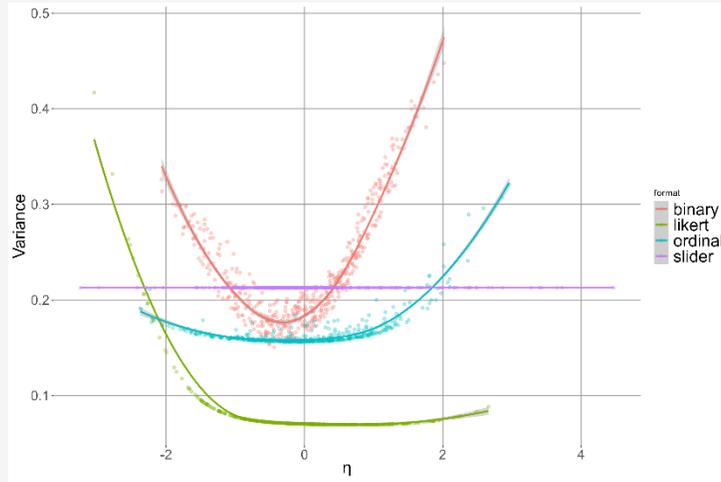
- リッカートがとても強い
- 二択よりは多肢選択のほうが情報量が多い
- スライダーは中途半端？

他の因子でも程度の違いはあれど
概ね同じ結果が得られた

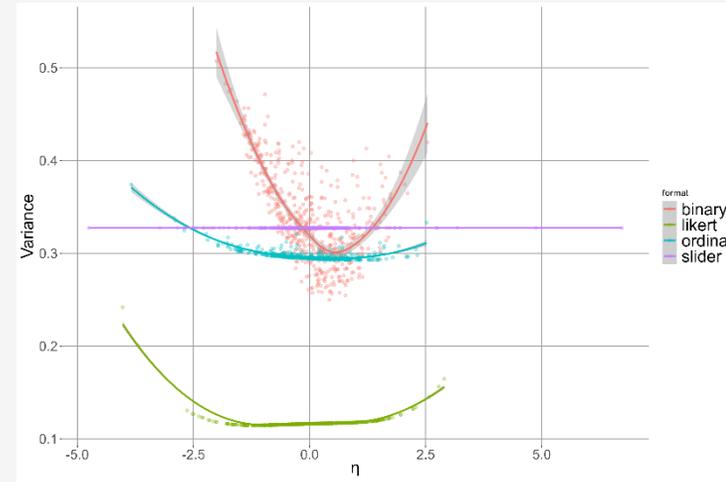
■ 因子2-5の分散のプロット

リックカート > スライダー ÷ 多肢選択 > 二択

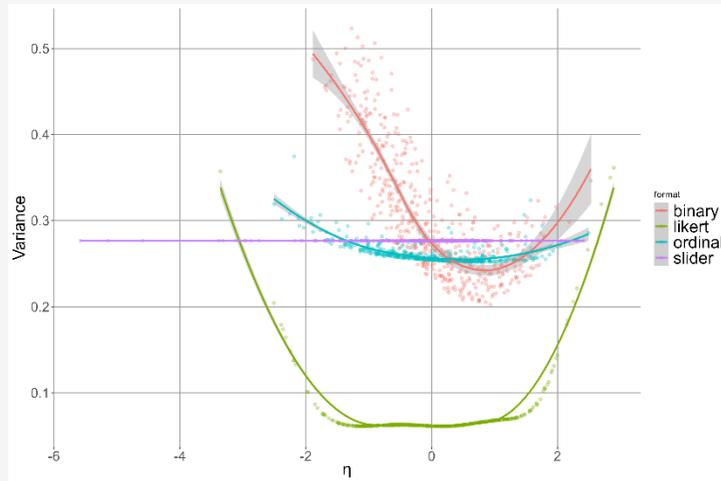
2



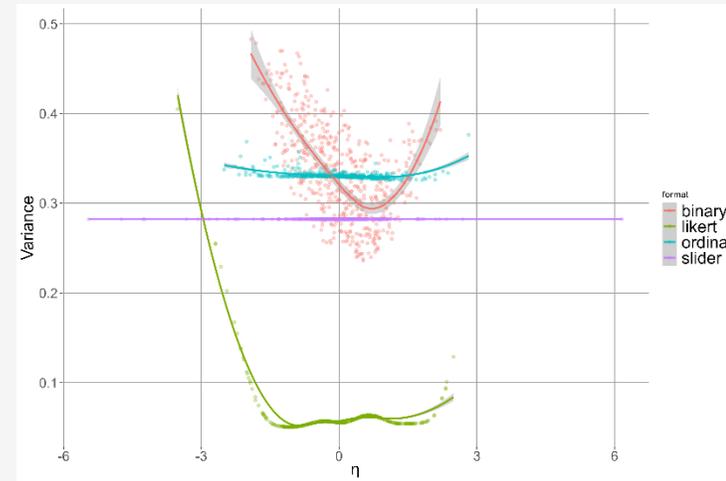
3



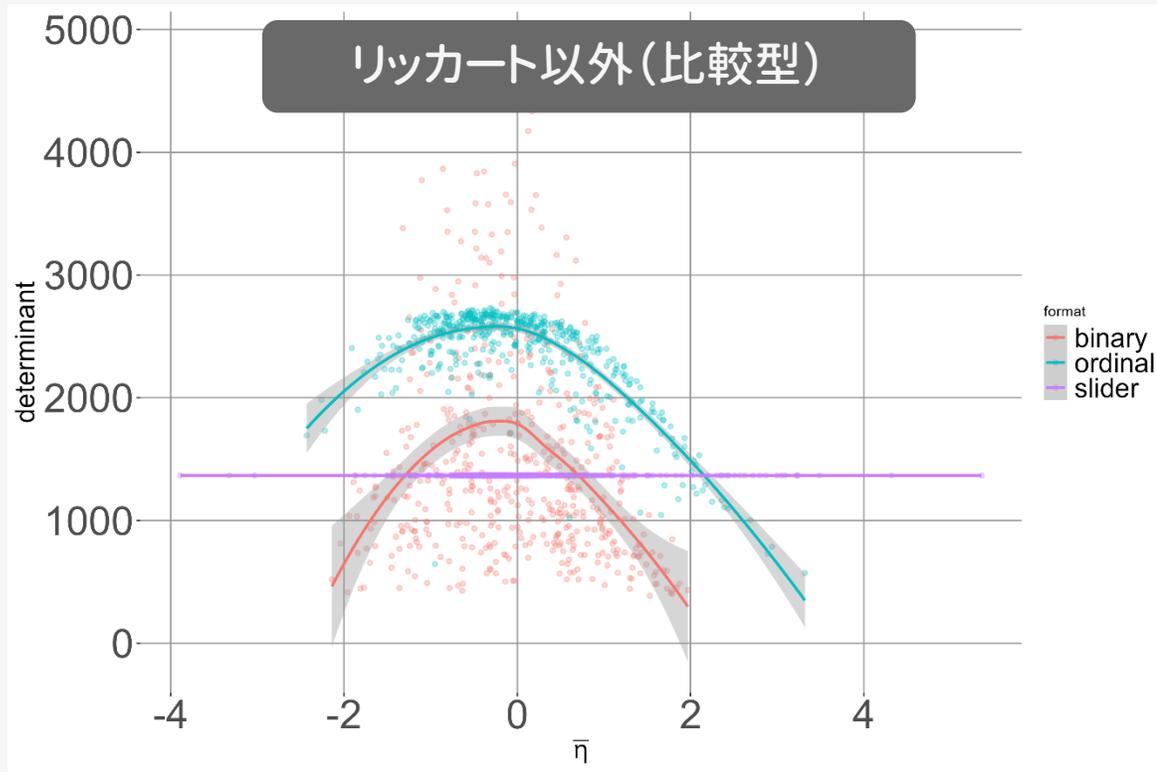
4



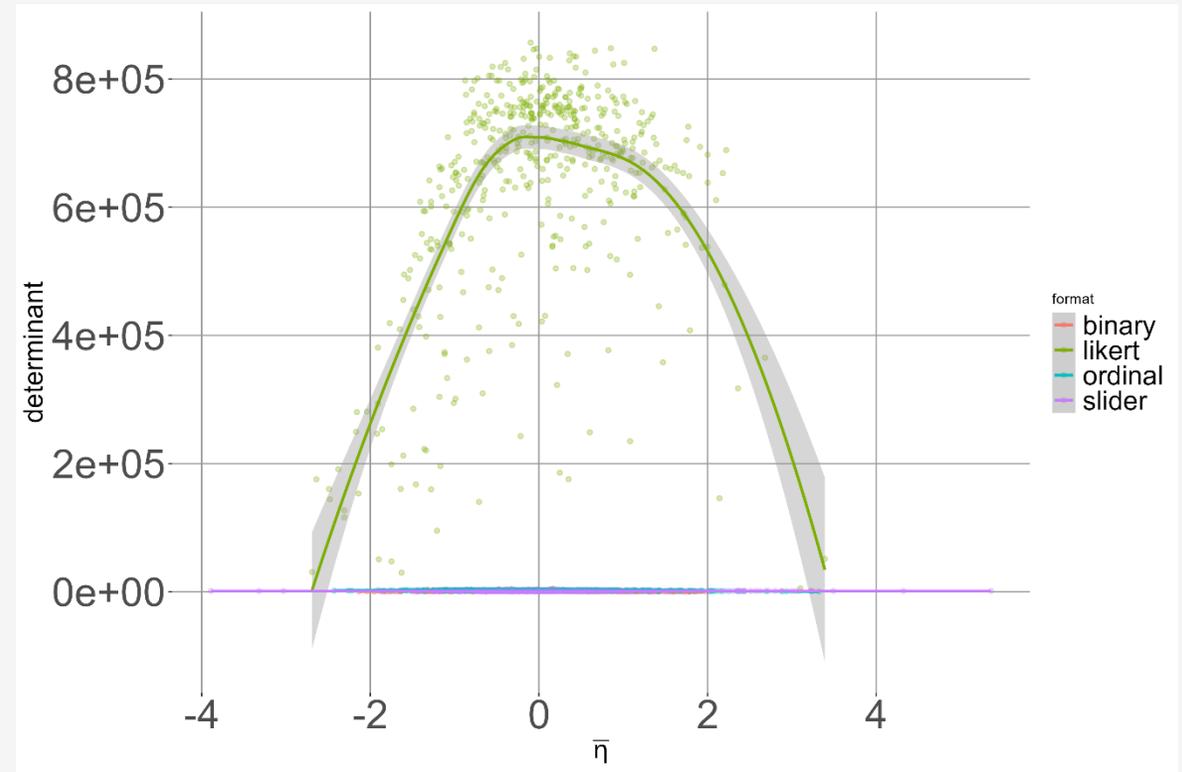
5



- 個人ごとのばらつきは大きい
多肢選択 > 二択
スライダーは場所による

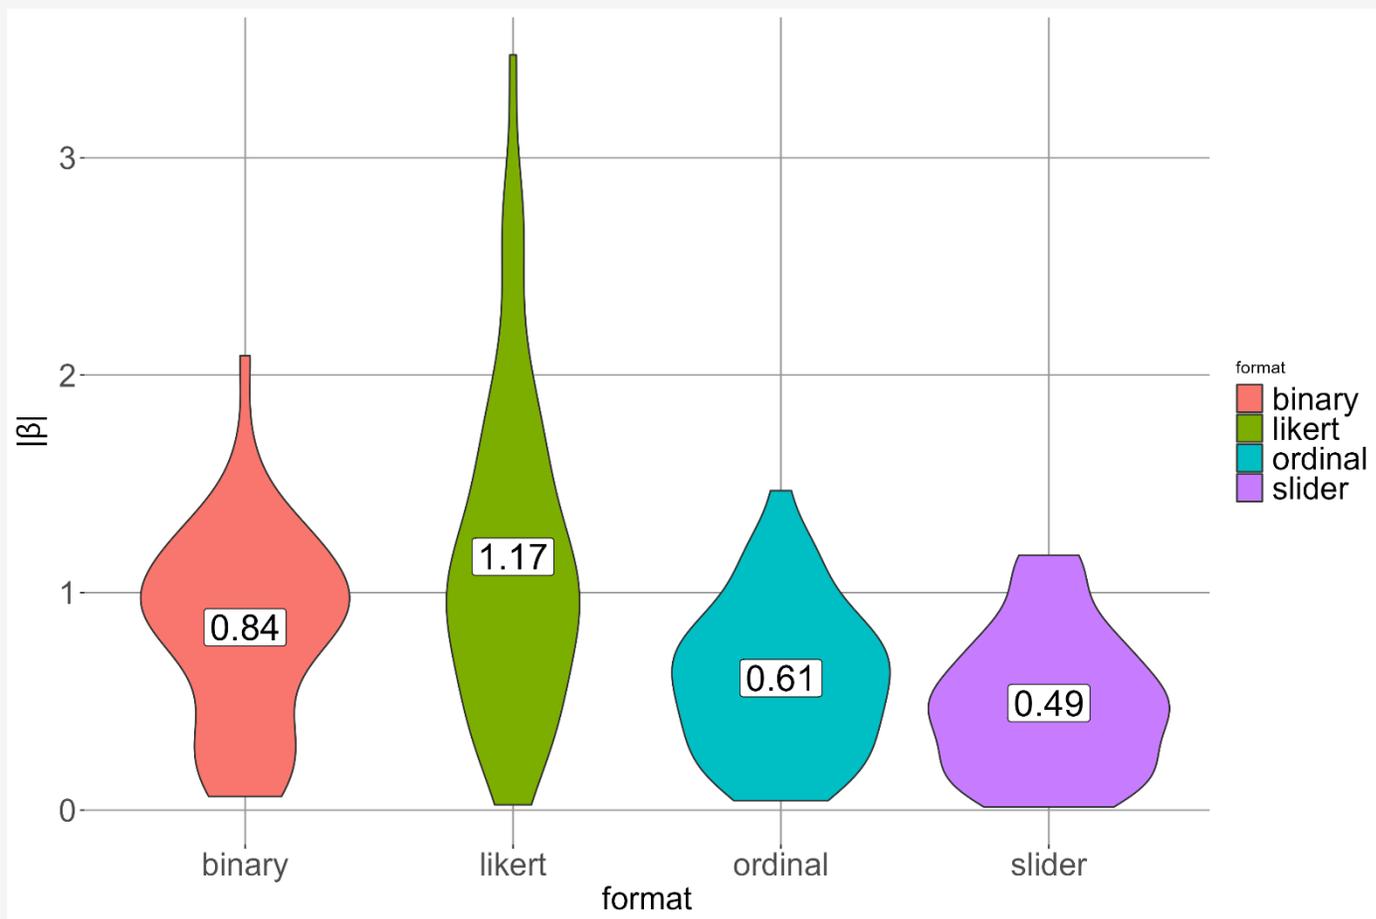


- リッカートが大きすぎる



■ 比較では因子負荷が低くなる

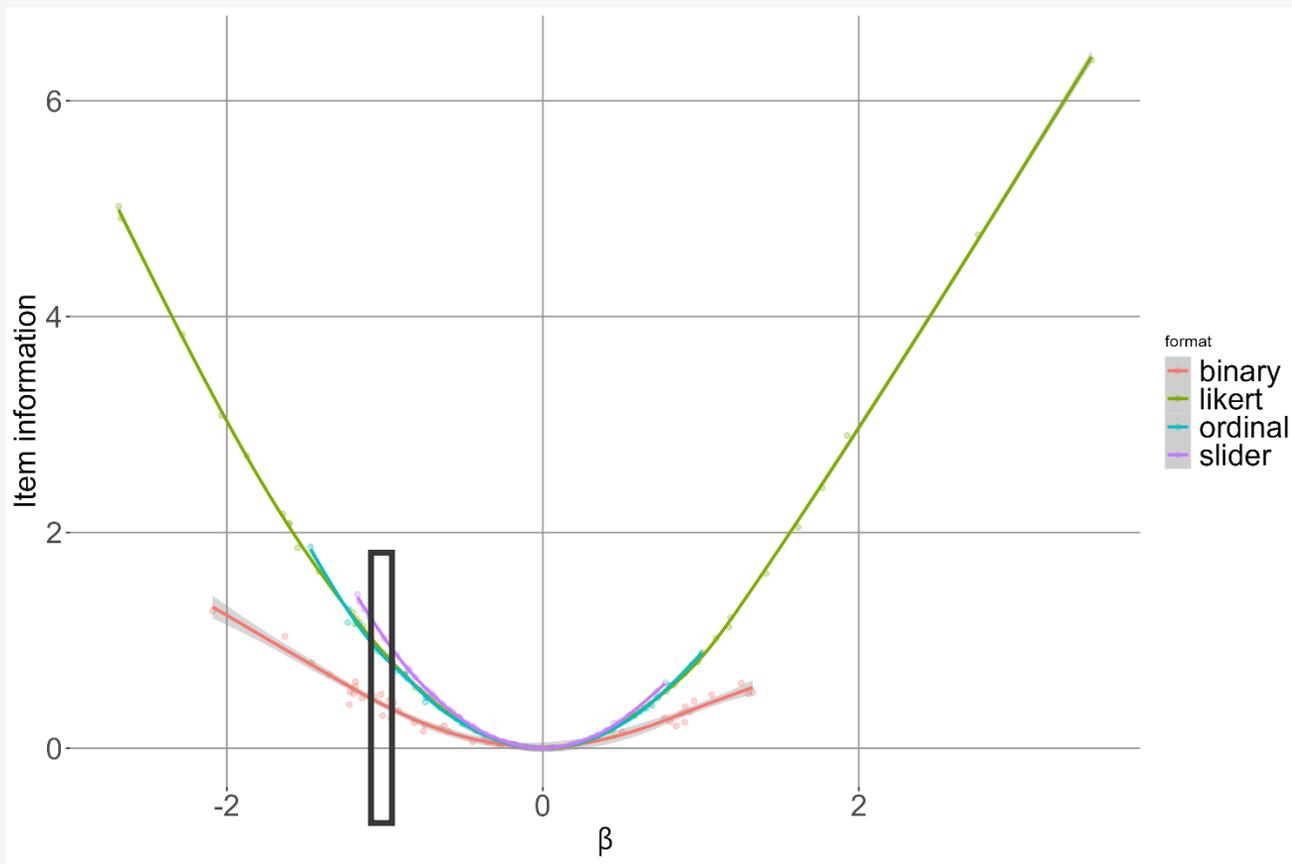
▲ 回答が「もう一方の文」によっても変わるため



- リッカートではたまに因子負荷の大きな項目が現れる
- 二択のほうが因子負荷は大きい?
 - ▶ カテゴリ化によるロスの影響
- スライダーは因子負荷が低くなりがち
 - ▶ 原因は要検討

■ 因子負荷と項目情報量の関係を見てみると

カーブの強さが 二択 < リッカート ≒ 多肢選択 < スライダー



- スライダーでは因子負荷が小さくても情報量が大きくなりやすい
▶ カテゴリ化による損失が少ないため
- リッカートと多肢選択はカテゴリ数が同じなので情報損失の程度も同じ?
- 二択では因子負荷が十分大きくなると情報量が大きくなる

■ 一問あたり回答時間の差

フォーマット	Mean	Trim10%	SD
二択	3.33	3.04	2.41
多肢選択	3.93	3.61	2.99
スライダー	4.18	3.86	2.76
リッカート	2.57	2.32	2.56



- 比較の場合は選択肢数が少ないほうが速い
▶ 多肢選択は時間がかかるが情報量が多い
- リッカートのほうが一問あたりは速い

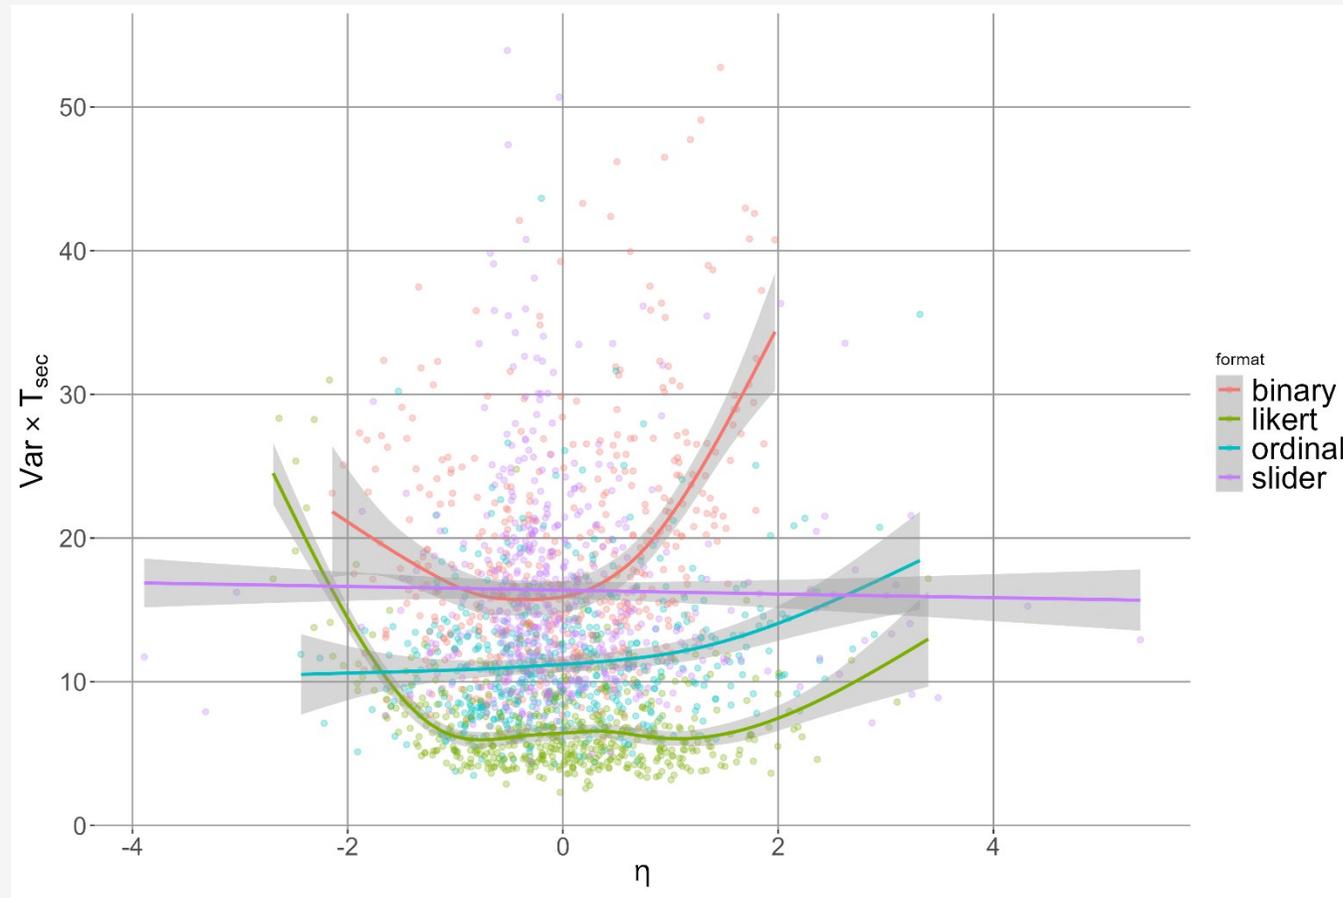
■ テスト全体での回答時間の差

	フォーマット	Mean	Trim10%	SD
25問	二択	83.26	80.62	32.72
	多肢選択	98.32	94.94	40.41
	スライダー	104.45	100.41	44.71
50問	リッカート	128.67	123.86	49.81



- 比較の場合は選択肢数が少ないほうが速い
- リッカートは項目数が倍なので遅い

■ 分散共分散行列 $I_j(\eta)^{-1}$ の(1,1)成分 = 因子1の分散 \times 合計回答時間のプロット

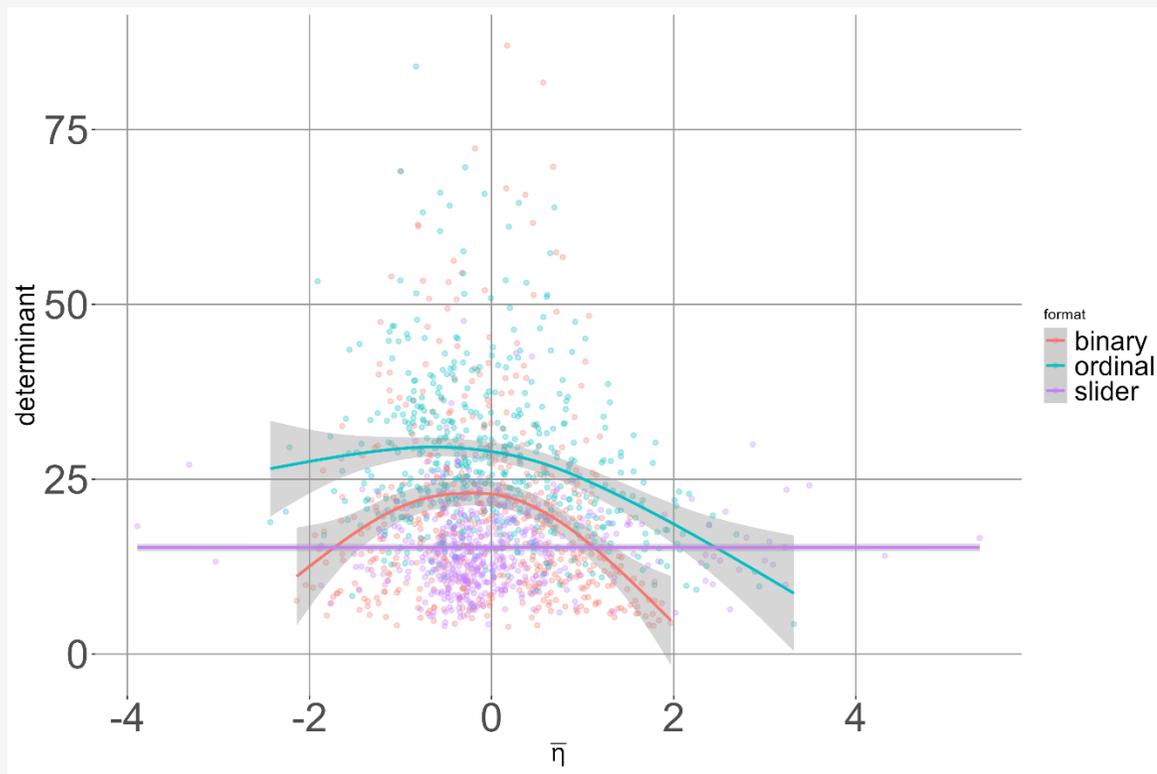


回答時間の違いは
優劣を覆すほどではない

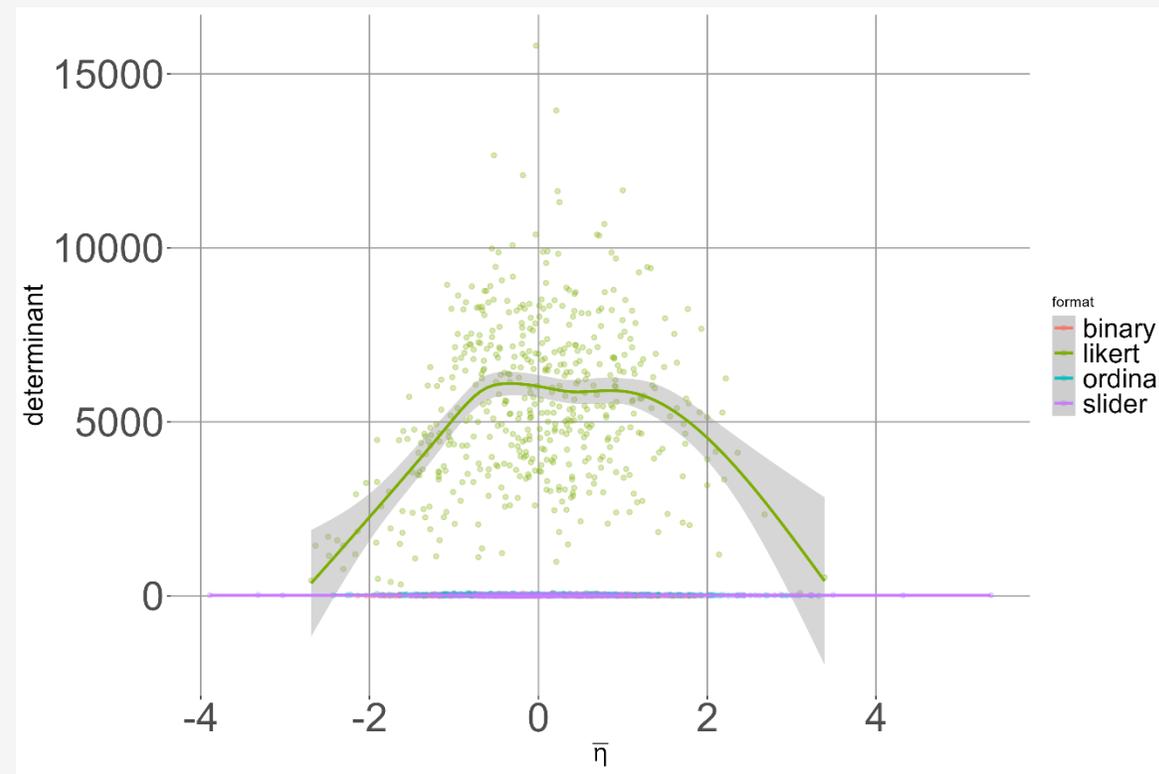
他の因子でも程度の違いはあれど
概ね同じ結果が得られた

■ 合計回答時間(秒)で割った値

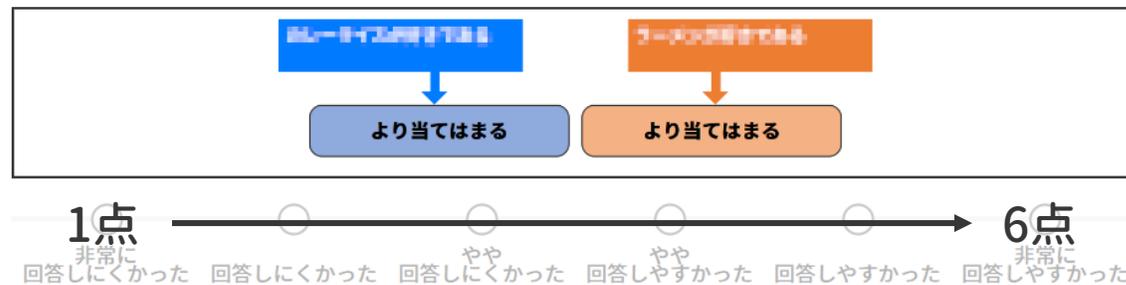
回答時間の個人差が大きいため不安定



■ 結局リッカートが大きすぎる



最後に、本実験で使用した4種類の回答形式について、どの程度回答しやすかったかを6段階で評価してください。



単純集計

フォーマット	Mean	SD
二択	3.48	1.38
多肢選択	3.64	1.17
スライダー	3.62	1.29
リッカート	4.69	0.96

分散分析

要因	SS	df	MS	F	p
個人差	928.2	499	1.86		
フォーマット	471.5	3	157.16	117.56	>.001
残差	2001.3	1497	1.34		
合計	3401.0	1999	1.70		

多重比較

比較型項目は
フォーマットに関係なく
リッカートより答えにくい

比較A	比較B	t	df	p	調整p
二択	多肢選択	2.33	499	.020	.061
	スライダー	1.83	499	.068	.136
	リッカート	15.68	499	>.001	>.001
多肢選択	スライダー	0.32	499	.748	.748
	リッカート	16.23	499	>.001	>.001
スライダー	リッカート	14.28	499	>.001	>.001

■ 異なるフォーマットにおける情報量を比較した

二択よりは多肢選択のほうが情報量が多かった(予想通り)

リッカートは強制選択よりも一項目あたり情報量がかなり多い

▲ 強制選択では識別力が低くなってしまふことの影響が大きい

スライダーはカテゴリ化の損失が少ない一方で識別力が低くなる

▲ モデルのせい? 回答の敏感性によるノイズのせい? 慣れていないせい?

■ 比較型項目の存在意義

多少の情報量を犠牲にしても

- フェイキングなどを抑制できる
- 異なる因子の個人内比較の情報が得られる(非対角成分)
- 意図的に認知負荷を上げることができる?

■ 回答の困難さのフォーマットによる違いを確認した

比較をさせる時点でリッカートより一段と難しくなる

▶ 比較させるならばどのフォーマットでも困難さはあまり変わらない

主観的には二択が最も答えにくいですが、回答時間は二択が最も速い

▶ いずれにせよ情報量の違いを覆すほどの差はない

■ 比較型項目を使うなら

カテゴリ数は人間が識別できる程度(7-9くらい?)に多めにするのが良さそう

※推定するパラメータの増加の影響などは要検討

■ 研究の限界

オンライン実験なのでどの程度真面目に回答してくれたか...