

日本テスト学会講演  
平成21年5月30日  
早稲田大学36号館

# テスト応答分析のための ベイズ的アプローチ

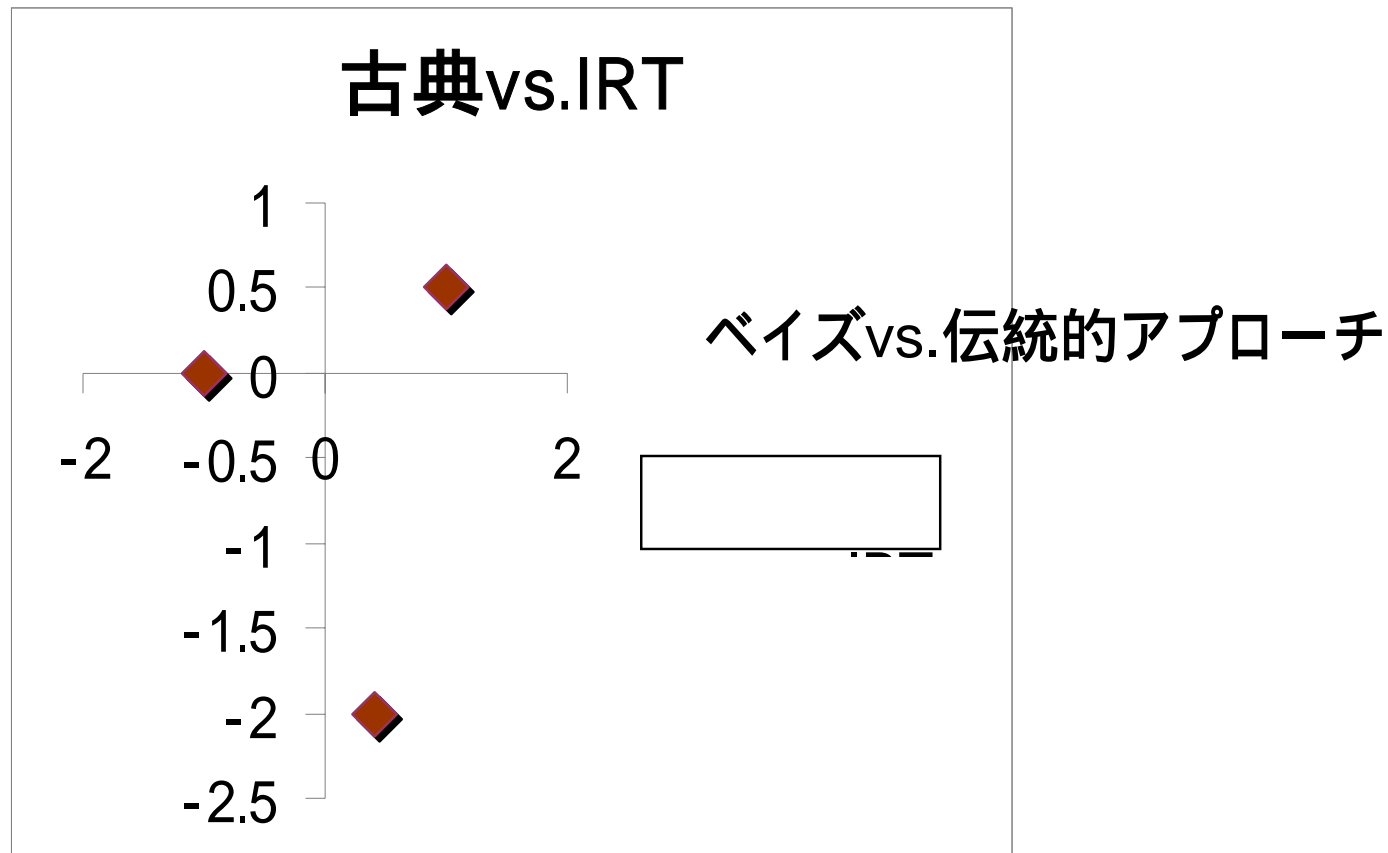
帝京大学  
繁柘算男

# OUTLINE

- 階層モデルとベイズ的アプローチの利点
- 項目応答へのベイズ的アプローチ: 項目反応理論と古典的テスト理論
- テスト応答分析へのベイズ的アプローチの応用

# 二つの対立( ? )軸

- 伝統的統計学(標本抽出理論) vs. ベイズ理論
- 古典的テスト理論 vs. 現代テスト理論(項目反応理論)
- あなたはどのように自分を位置付けますか？



# 1. ベイズ統計学とは？

確率法則を認知的に根拠のある体系として、  
 $P(\text{未知のもの} \mid \text{既知のもの})$   
を得るために用いる。

- 未知の知りたいこと:
- 既知の観測されたもの:  $X$  (データあるいは割り当てを示すダミー変数は、観測されることのあり、観測されないこともある。 e.g. 将来のデータ、調査観察研究の場合の割り当て。)

$$p(\theta | X) \propto p(X | \theta) p(\theta)$$

- 主観的な設定が必要なもの  
データ(発生)モデル  
事前分布      **AND**  
データ取得メカニズム (eg. treatment assignment mechanism)

## 2 . 階層モデル

- ベイズはもともと階層的

$$p(\theta | X) \propto p(X | \theta, \tau, \xi) p(\theta | \tau, \xi) p(\tau | \xi)$$


where  $\theta$  : parameter,  $\tau$  : hyper - parameter,

and  $\xi$  : super - parameter

# 階層的に考える場合の注意

- 何を知りたいか？ (e.g. 将来の観測値か、パラメータか?)
- 何がわかっていて何がわかっていないか？ (e.g. 観測メカニズムは既知か?)
- 何が観測されるか？
- 未知の物を推論するために必要なものが抜けていないか？無駄なものが入っていないか？ (e.g. 観測メカニズムの知識は必要か?)
- モデルはなるべく“客観的”にする。即ち、だれしものが納得するようにしたい。

# 3. Rubin因果モデル



x: randomized experiment

: ignorable treatment assignment

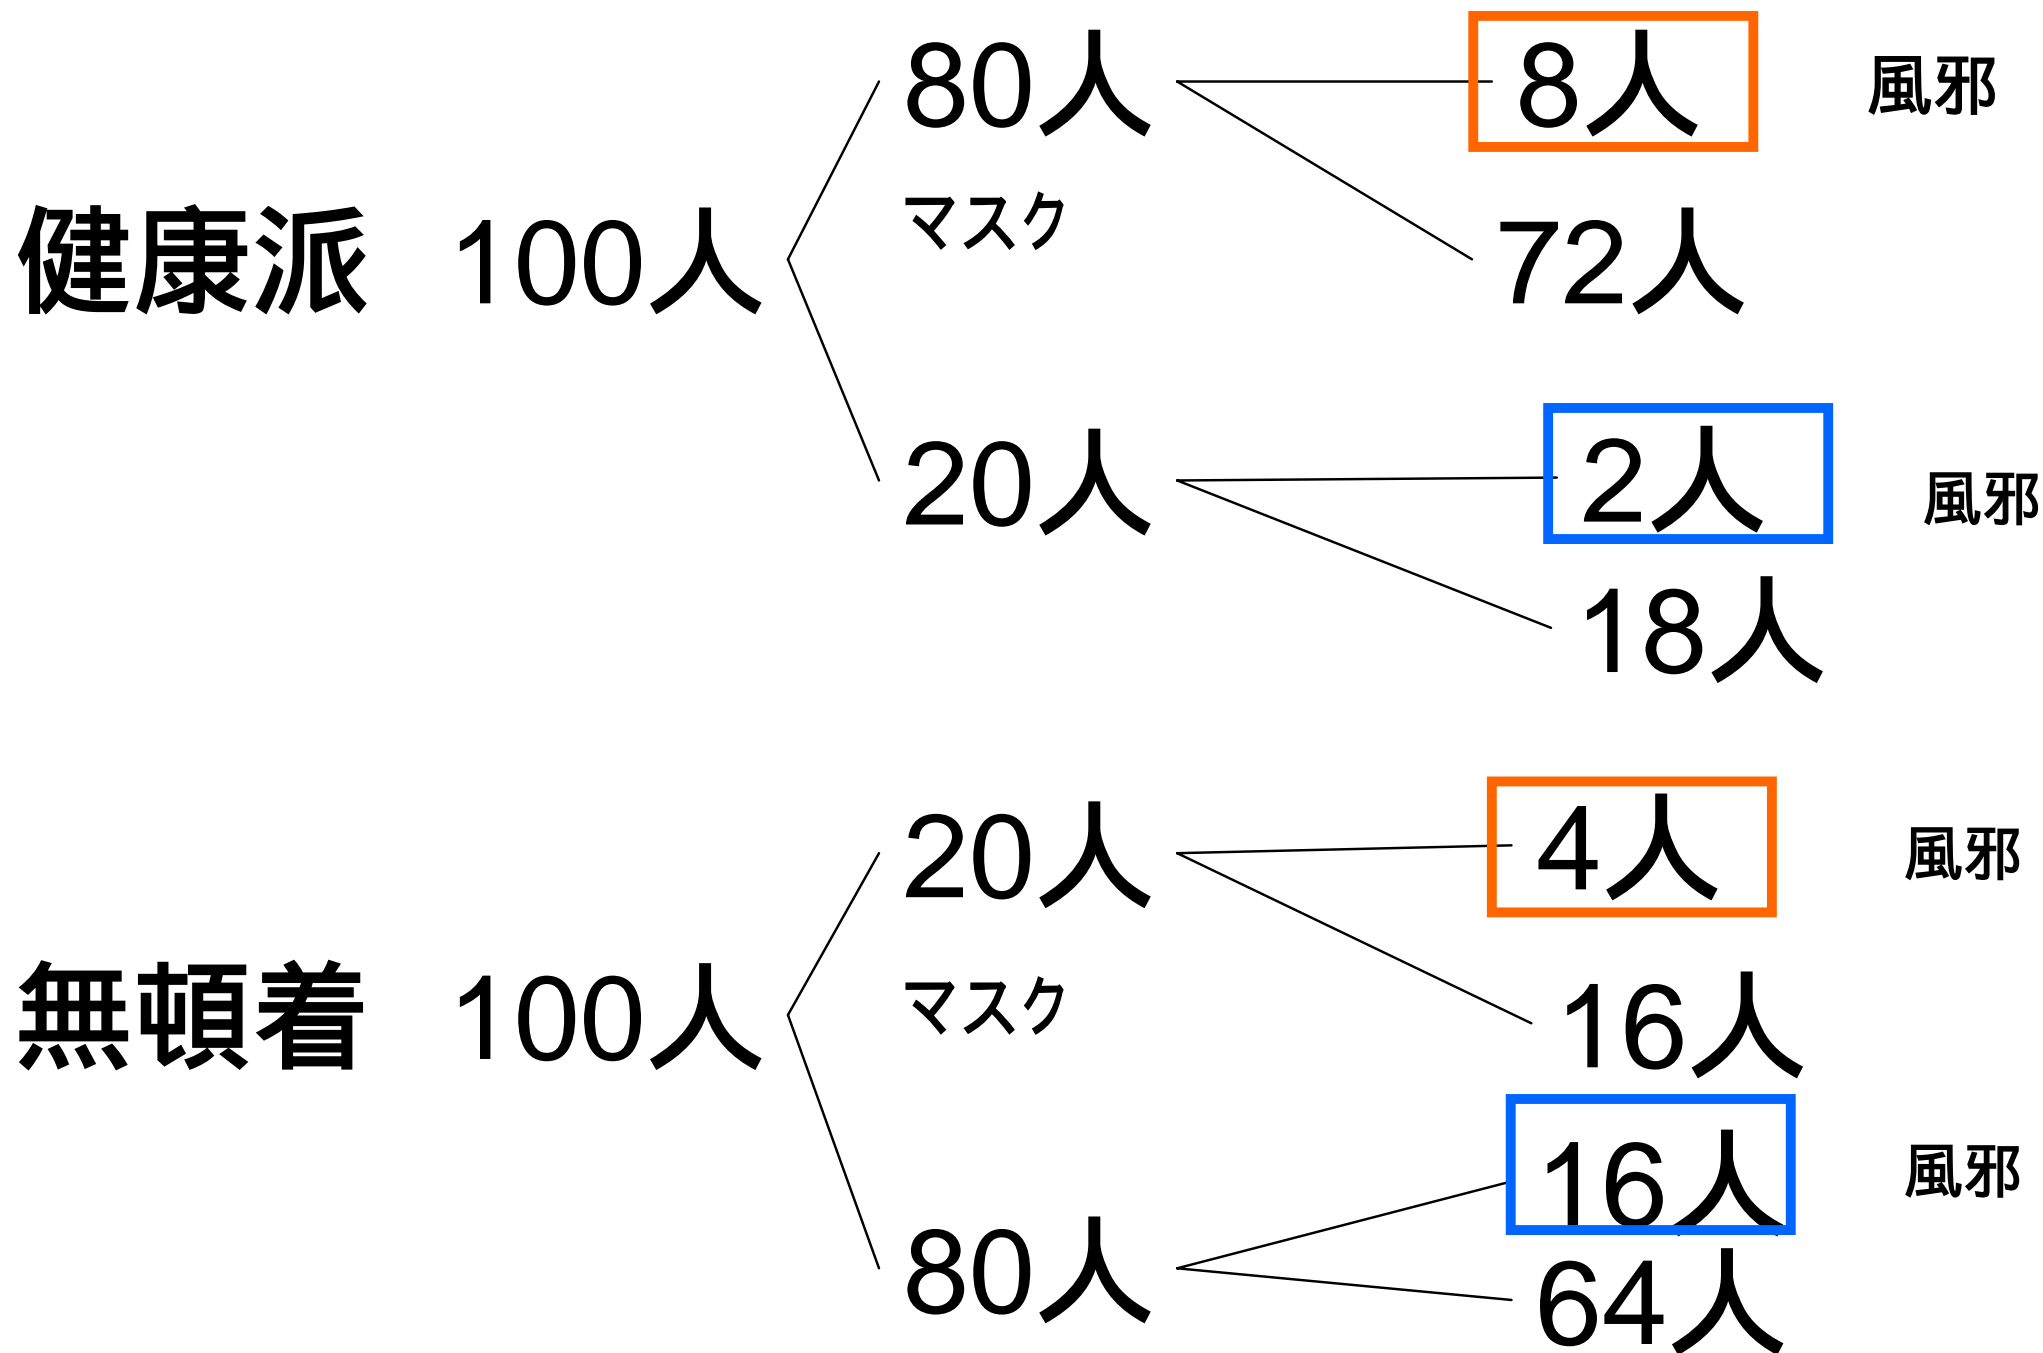


# マスクは役に立つか？

- 同じ人がマスクをした場合とマスクをしない場合を比較する。これは無理。
- ゆえに、同じ条件で、交換可能な観測ユニットを探す。理想的には、単純無作為化実験、 $a$ あるいは、共変数(健康意識)を所与として、確率化実験。たとえば、風邪にかかりたくないと強く思う人100人の8割にマスク、2割にマスクを着用させない。無頓着な人100人の2割にマスクを着用させ、8割にはそのまま。(無視可能な実験デザイン)。

# 架空データ

- 健康に気をつける人の内、マスクをした人の1割が風邪を引き、同様に、マスクをしていない人も1割が風邪を引いた。また、無頓着な人の内、マスクをした人もしない人も2割が風邪を引いた。もし母集団において健康に注意する人無頓着な人が5分5分だとすると、母集団では、マスクをつける人もつけない人も15パーセントが風邪を引くことになり、マスクの効果がないことは明らかである。



# 確率化が行われない場合

ここで単純にデータ発生メカニズムを無視すれば、マスクをした人100人の内12人(健康派80人の1割、無頓着20人の2割)が風邪を引き、マスクをしない人100人の内18人(健康派20人の1割無頓着80人の2割)、マスクをする効果があると誤って結論するかも知れない。

research model

assignment mechanism

$$p(Y_{mis} | X, Y_{obs}, W)$$

$$= \frac{p(X, Y(0), Y(1)) P(W | X, Y(0), Y(1))}{\int p(X, Y(0), Y(1)) P(W | X, Y(0), Y(1)) dY_{mis}},$$

ignorable treatment assignment が成立するならば、

$$= \frac{P(X, Y(0), Y(1))}{\int P(X, Y(0), Y(1)) dY_{mis}}$$

(cf. ignorable assignment :

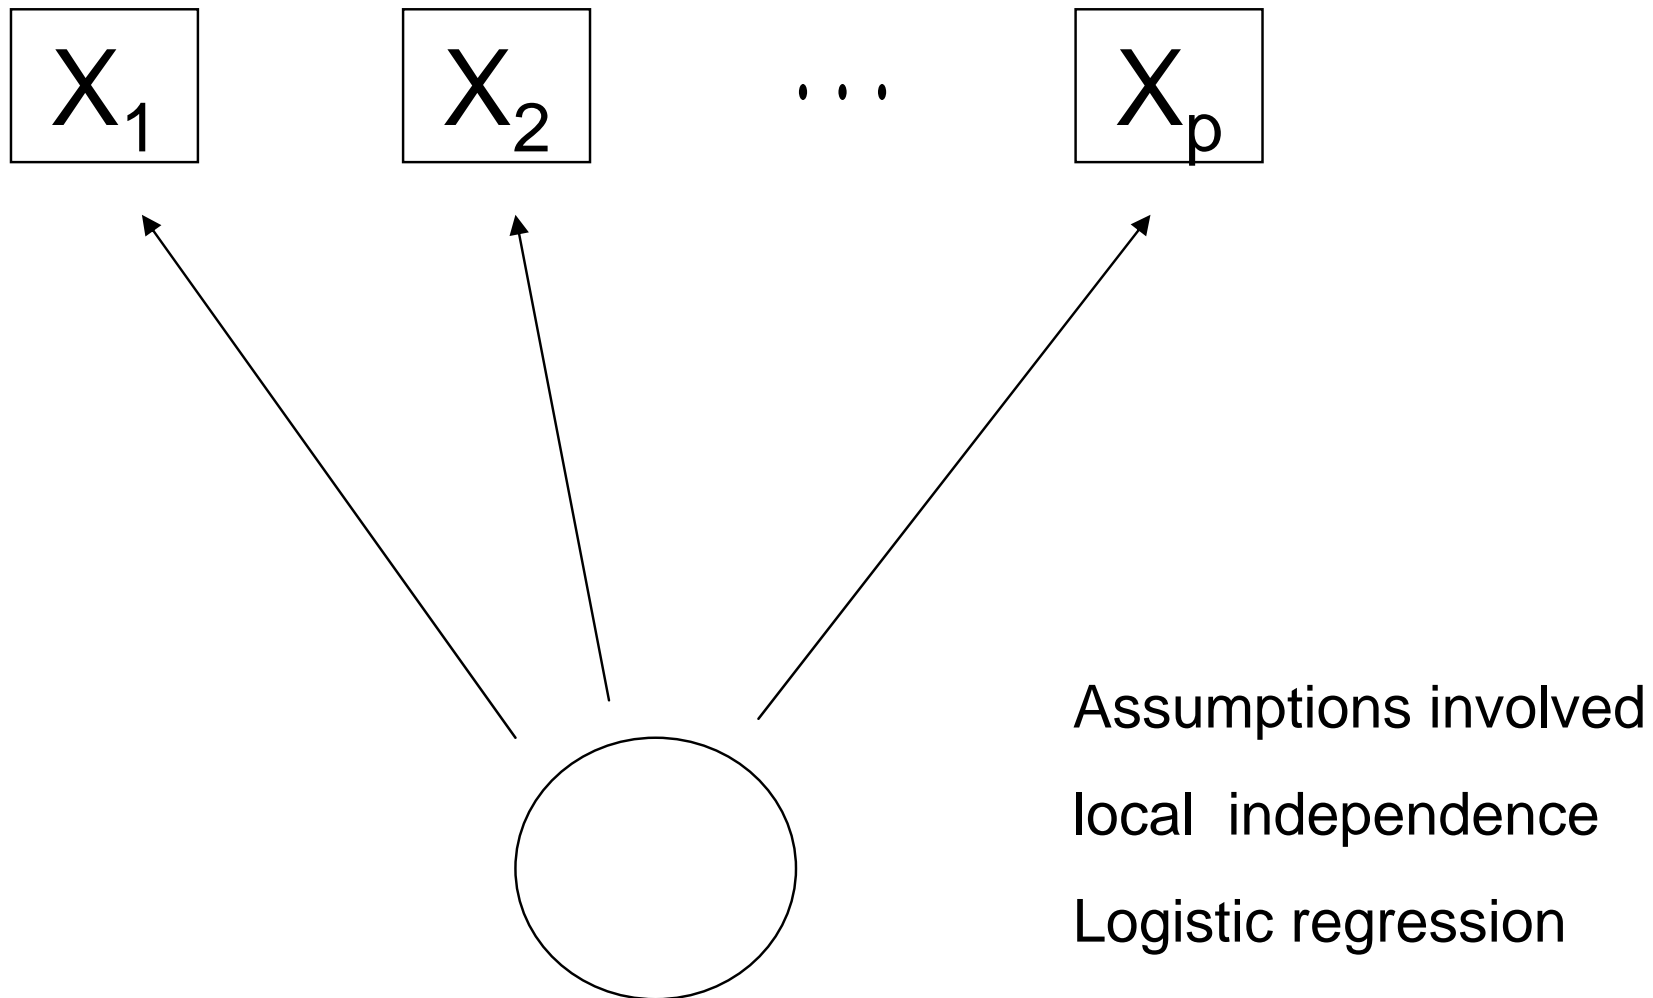
$$P(W | X, Y(0), Y(1)) = P(W | X, Y_{obs}))$$

# 一般的な図式


$$\begin{aligned} p(\theta | X, W) &= \frac{p(\theta, X)P(W | \theta, X)}{\int p(\theta, X)P(W | \theta, X)d\theta} \\ &= \frac{p(\theta)p(X | \theta)P(W | \theta, X)}{\int p(\theta)p(X | \theta)P(W | \theta, X)d\theta} \end{aligned}$$

通常の調査観察研究では、観測メカニズムは無視される。

# 4. 項目反応(応答)理論




# 大問形式(ブックレットモデル)



Assumptions involved;  
Multi-Normality within  
a group of items



## 5. 古典的テスト理論 (真の得点理論)



- 期待値  $\mu_i$  は一様には定義できない  
一般化可能性理論
- 期待値  $\mu_i$  は知りたい値  $\mu_i$  とは異なる  
階層的理論へ

# 5-1 一般化可能性理論

$$x_{ijk} = \tau_i + \gamma_k + \varepsilon_{ijk}$$

where  $i$  :  $i$  - th unit,

$j$  :  $j$  - th rater, and  $k$  :

$k$  - th repetition

ベイズ的アプローチの利点:いろいろな分散成分の関数、  
たとえば、各種の信頼性係数の分布を導くことができる。


## 5-2 妥当性の問題

- いかにかが と関係しているか
- 相関係数

$$x = G_x(\tau) + \varepsilon_x$$

$$y = G_y(\theta) + \varepsilon_y$$


- 構成概念 ( )




真の値 ( )

CU : Construct Underrepresentation


CIV : Construct Irrelevant Variance



- Construct (知能)
- Test (頭囲)



- Construct (知能)
- Test (脳容量)



- Construct (知能)
- Test (知能テスト)
- CU : 創造性、時間をかけた問題解決力
- CIV : テストワイズネス

# 理論的関心と実践的関心

- 二つの構成概念はどの程度関連しているか？  
と の相関の推定
- テストは構成概念とどの程度関連しているか？  
 $x$ と の相関の推定
- テストは現実の基準をどの程度予測するか？  
 $x$ と $y$ の相関の推定

# 希薄化の修正

$$P(\theta, \tau | x, y)$$

$$\propto p(x, y | \tau, \theta) p(\tau) p(\theta)$$

$$= p(y | x, \tau, \theta) p(x | \tau, \theta) p(\tau) p(\theta)$$

この一般的な式を従来の希薄化の修正式は、  
単純化し、点推定値のみ求めている。

$$p(x | \tau) p(y | \xi) p(\tau) p(\xi)$$

# 選択母集団の問題

$$\begin{aligned} p(x, y) &= p(x, y | w = 1)P(w = 1) \\ &+ p(x, y | w = 0)P(w = 0) \\ &= p(y | x, w = 1)P(w = 1 | x)p(x) \\ &+ \boxed{p(y | x, w = 0)}P(w = 0 | x)p(x) \end{aligned}$$

$y$ : *gpa*    $x$ : 入試得点

$w = 1$ : 合格    $w = 0$ : 不合格

$P(w = 1 | x)$    or    $P(w = 0 | x)$    : 大量データにより推定

$p(y | x, w = 0)$    : regression model



# テスト使用の究極の妥当性： 結果的妥当性

ある意思決定において、テスト情報を用いて決定した場合に予想する効用(期待効用)と、テスト情報を用いないで決定した場合に予想する効用(期待効用)の差をテストの情報価値(Expected Value of Test Information, EVTI)と呼ぶ。

EVTI

$$= \int_X \max_i \left\{ \int u(a_i, \theta) p(\theta | x) d\theta \right\} p(x) dx$$
$$- \max_i \left\{ \int u(a_i, \theta) p(\theta) d\theta \right\}$$

# 6. まとめ: ベイズ的アプローチの利点

- 単純な場合
  - ほぼ同じ結果(解釈は異なる)
  - 例: 単純無作為実験(cf. Neyman, 1923)
- 複雑な場合
  - 異なる結果
  - モデル建立が容易
  - 解釈がしやすい
  - パラメータの分布がわかる
  - 確率的言明が直接手に入る

# テスト得点への応用における利点

- テスト応答の発生モデルは単純ではない。  
(正規分布が妥当なのは、潜在変数くらいである。) 複雑なデータモデルを必要とする。(将来の夢: ベイズ的ネットワークによる記述式回答の自動採点)
- テストは常に何かを目的として使用される。すなわち、意思決定の枠組みで考えるべきであり、ベイズ的アプローチはこの枠組みと相性がよい。