

項目反応理論に関するいくつかの話題

前川眞一

東京工業大学
大学院社会理工学研究科
2012.12.08 JART

アウトライン

2

0. 多項分布の確率の推定
1. 項目パラメタの推定
2. 順序カテゴリの取り扱い
3. 重み付き得点からの θ の推定
4. 独立に推定された項目パラメタの等化

0. 多項分布の確率の推定

3

1-1

数値的カテゴリを持つ多項分布の確率の推定

1-2

数値的カテゴリを持つ多項分布の和の分布

1-3

カテゴリカルデータの回帰分析

0-1 数値的カテゴリを持つ多項分布の確率の推定

4

● 数値的カテゴリを持つ多項分布

Y を値域 $\{A_1, A_2, \dots, A_m\}$ を持つ離散型確率変数とする。
 $(m+1) \times 1$ のダミー変数 Z ベクトルを

$$Z_k = \begin{cases} 1 & \text{if } Y = A_k, k = 1, 2, \dots, m \\ 0 & \text{otherwise} \end{cases}$$

と定義すると Z は多項分布をする。

$$Z \sim MN(1, \pi)$$

ただし、 π は以下を満たすカテゴリの生起確率ベクトルである。

$$\pi = (\pi_1, \pi_2, \dots, \pi_m), \quad \pi_k > 0, \quad \sum_{k=1}^m \pi_k = 1$$

Z の確率関数は

$$\Pr(Z_1 = z_1 \& Z_2 = z_2 \& \dots \& Z_m = z_m | \pi) = \prod_{k=1}^m \pi_k^{z_k}$$

0-1 数値的カテゴリを持つ多項分布の確率の推定 5

n 個の観測値

$$z_i = (z_{i1}, z_{i2}, z_{i3}, \dots, z_{im}), \quad i = 1, 2, \dots, n$$

を与えられた時のパラメタ π の尤度は

$$L(\pi) = \prod_{i=1}^n \prod_{k=1}^m \pi_k^{z_{ik}}$$

n 個の観測値から計算した度数分布

$$(A_k, f_k), \quad k = 1, 2, \dots, m$$

ただし

$$f_k = \sum_{i=1}^n z_{ik}, \quad \sum_{k=1}^m f_k = n$$

が与えられた時のパラメタ π の尤度は

$$L(\pi) = \prod_{k=1}^m \pi_k^{\sum_{i=1}^n z_{ik}} = \prod_{k=1}^m \pi_k^{f_k}$$

である。

0-1 数値的カテゴリを持つ多項分布の確率の推定 6

尤度関数

$$L(\pi) = \prod_{k=1}^m \pi_k^{f_k}$$

を最大とするパラメタの推定値、最尤解は

$$\pi_k = \frac{f_k}{\sum_{k'=1}^m f_{k'}} = \frac{f_k}{n}$$

である。

多項分布のカテゴリの値 $\{A_1, A_2, \dots, A_m\}$ が数値の場合、

π_k を A_k の関数として表すことを考える。すなわち

$$\pi_k \propto g(A_k | \xi)$$

または

$$\pi_k = \pi_k(A_k) = \frac{g(A_k | \xi)}{\sum_{k=1}^m g(A_k | \xi)}$$

とする。

0-1 数値的カテゴリを持つ多項分布の確率の推定 7

多項分布の確率

$$\Pr(Y = A_k) = \Pr(Z_k = 1) = \pi_k$$

をカテゴリの関数として求める。

$$\pi_k = \pi_k(A_k) = \frac{g(A_k | \xi)}{\sum_{k=1}^m g(A_k | \xi)}$$

ただし、 ξ は関数 g の形を決めるパラメタで、(対数) 尤度関数

$$L(\xi) = \prod_{k=1}^m \pi_k^{f_k} = \prod_{k=1}^m \left(\frac{g(A_k | \xi)}{\sum_{k'=1}^m g(A_{k'} | \xi)} \right)^{f_k}$$

$$\ln L(\xi) = \sum_{k=1}^m f_k \log \left(\frac{g(A_k | \xi)}{\sum_{k'=1}^m g(A_{k'} | \xi)} \right)$$

を最大とするようにして求める。

0-1 数値的カテゴリを持つ多項分布の確率の推定 8

● g の例

- Normal pdf: $\xi = (\mu, \sigma)$

$$g(A_k | \xi) = \exp(-0.5(A_k - \mu)^2 / \sigma)$$

- Normal cdf: $\xi = (\mu, \sigma)$

$$g(A_k | \xi) = \Phi \left(\frac{(A_k + A_{k+1})/2 - \mu}{\sigma} \right) - \Phi \left(\frac{(A_{k-1} + A_k)/2 - \mu}{\sigma} \right)$$

0-1 数値的カテゴリを持つ多項分布の確率の推定 9

● Fisher のスコア法によるパラメタの推定

対数尤度関数の一次偏微分

$$\frac{\partial \ln L}{\partial \xi} = \sum_{k=1}^m (f_k - n\pi_k) \frac{\partial \log g(A_k | \xi)}{\partial \xi} = \sum_{k=1}^m \frac{(f_k - n\pi_k)}{g(A_k | \xi)} \frac{\partial g(A_k | \xi)}{\partial \xi}$$

Fisher Information Matrix

$$\mathbf{H}(\xi) = \mathbf{E} \left(\left(\frac{\partial \ln L}{\partial \xi} \right) \left(\frac{\partial \ln L}{\partial \xi} \right)' \right) = n \mathbf{S}(\xi)' (\text{Diag}(\boldsymbol{\pi}) - \boldsymbol{\pi} \boldsymbol{\pi}') \mathbf{S}(\xi)$$

ただし

$$\mathbf{S}(\xi) = \frac{\partial \log g(\mathbf{A} | \xi)}{\partial \xi} = \left\{ \frac{\partial \log g(A_k | \xi)}{\partial \xi_\ell} \right\} = \left\{ \frac{1}{g(A_k | \xi)} \frac{\partial g(A_k | \xi)}{\partial \xi_\ell} \right\}$$

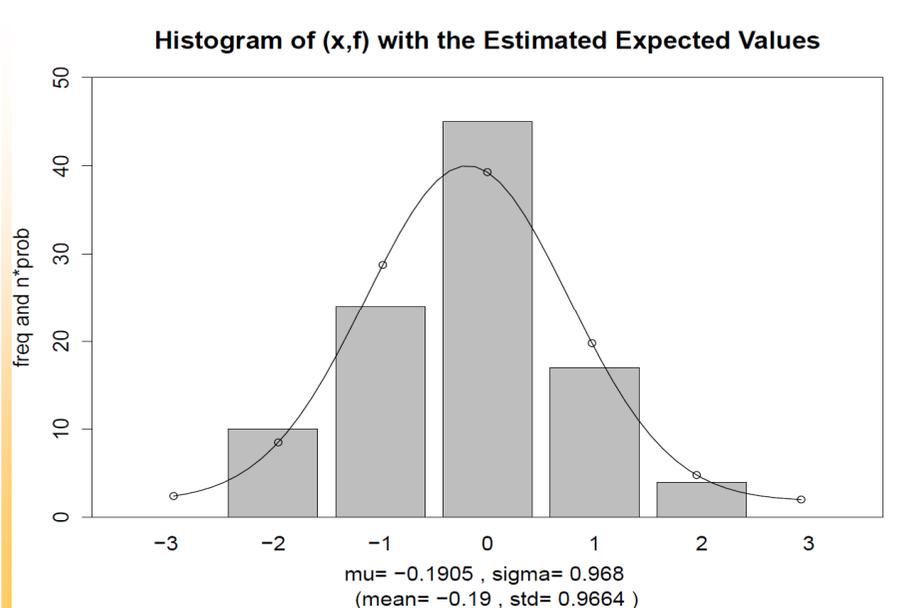
$k = 1, 2, \dots, m, \ell = 1, 2, \dots, \dim(\xi)$

0-1 数値的カテゴリを持つ多項分布の確率の推定 10

● データ n=100 normal pdf model

| A | f | n*pi | pi |
|----|----|--------|-------|
| -3 | 0 | 0.610 | 0.006 |
| -2 | 10 | 7.183 | 0.071 |
| -1 | 24 | 29.059 | 0.290 |
| 0 | 45 | 40.432 | 0.404 |
| 1 | 17 | 19.348 | 0.193 |
| 2 | 4 | 3.184 | 0.031 |
| 3 | 0 | 0.180 | 0.001 |

0-1 数値的カテゴリを持つ多項分布の確率の推定 11



0-1 数値的カテゴリを持つ多項分布の確率の推定 12

● その他

平均と分散の制約を付けた確率の推定

$$\text{平均 : mean} = \sum_{k=1}^m A_k \pi_k$$

$$\text{分散 : var} = \sum_{k=1}^m A_k^2 \pi_k - \left(\sum_{k=1}^m A_k \pi_k \right)^2$$

0-2 数値的カテゴリを持つ多項分布の和の分布¹³

多項分布のカテゴリが $m + 1$ の数値 $\{0, 1, 2, \dots, m\}$ から形成されている場合、それを数値化された多項分布と呼び

$$Y \sim MN((0, 1, \dots, m), \pi), 0 \leq Y \leq m$$

と記す。ただし、 $\pi = \{\pi_0, \pi_1, \pi_2, \dots, \pi_m\}$ は

$$\sum_{k=0}^m \pi_k = 1,$$

を満たす各カテゴリの生起確率であり、 m をその分布の満点とよぶ。

0-2 数値的カテゴリを持つ多項分布の和の分布¹⁴

定理 数値化された多項分布をする確率変数の和の分布

独立な二つの数値化された多項分布をする確率変数

$$Y_1 \sim MN((0, 1, \dots, m_1), \pi_1), 0 \leq Y_1 \leq m_1, \quad \pi_1 = (\pi_{01}, \pi_{11}, \pi_{21}, \dots, \pi_{m_11})$$

$$Y_2 \sim MN((0, 1, \dots, m_2), \pi_2), 0 \leq Y_2 \leq m_2, \quad \pi_2 = (\pi_{02}, \pi_{12}, \pi_{22}, \dots, \pi_{m_22})$$

を、正の整数 w_2 を重みとして加えたもの $Y_{1+2} = Y_1 + w_2 Y_2$ は、満点が $m_1 + w_2 m_2$ の数値化された多項分布

$$Y_{1+2} = Y_1 + w_2 Y_2, \sim MN((0, 1, \dots, m_1 + w_2 m_2), \pi_{1+2}), 0 \leq Y_{1+2} \leq m_1 + w_2 m_2$$

となり、その生起確率 π_{1+2} は

$$\pi_{1+2} = \sum_{k=0}^{m_2} z_k$$

0-2 数値的カテゴリを持つ多項分布の和の分布¹⁵

- 定理の続き

$$\pi_{1+2} = \sum_{k=0}^{m_2} z_k$$

ただし、

$$z_k = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ \pi_{k2} \pi_1 \\ 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \left. \begin{array}{l} \left. \vphantom{\begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ \pi_{k2} \pi_1 \\ 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}} \right\} w_2 k \times 1 \\ \left. \vphantom{\begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ \pi_{k2} \pi_1 \\ 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}} \right\} (m_1 + 1) \times 1 \\ \left. \vphantom{\begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ \pi_{k2} \pi_1 \\ 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}} \right\} w_2 (m_2 - k) \times 1 \end{array} \right\}$$

であたえられる。

0-2 数値的カテゴリを持つ多項分布の和の分布¹⁶

- 例 2点満点と3点満点のテストの和

$m_1 = 2, m_2 = 3, w_2 = 2$ の場合の例

この場合、 $\pi_1 = \{\pi_{01}, \pi_{11}, \pi_{21}\}$ また $\pi_2 = \{\pi_{02}, \pi_{12}, \pi_{22}, \pi_{32}\}$ であり、 π_{1+2} は $(2 + 2 \times 3 + 1) \times 1$ のベクトルとなる。

$$\pi_{1+2} = \begin{pmatrix} 0 \\ \pi_{02} \begin{pmatrix} \pi_{01} \\ \pi_{11} \\ \pi_{21} \end{pmatrix} \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} + \begin{pmatrix} 0 \\ 0 \\ \pi_{12} \begin{pmatrix} \pi_{01} \\ \pi_{11} \\ \pi_{21} \end{pmatrix} \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} + \begin{pmatrix} 0 \\ 0 \\ 0 \\ \pi_{22} \begin{pmatrix} \pi_{01} \\ \pi_{11} \\ \pi_{21} \end{pmatrix} \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} + \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ \pi_{32} \begin{pmatrix} \pi_{01} \\ \pi_{11} \\ \pi_{21} \end{pmatrix} \\ 0 \\ 0 \\ 0 \end{pmatrix}$$

0-3カテゴリカルデータの回帰分析

17

データ $(y_i, \mathbf{x}_i), i = 1, 2, \dots, n$

$(z_i, \mathbf{x}_i), i = 1, 2, \dots, n$

$(\mathbf{r}_i, n_i, \mathbf{x}_i), i = 1, 2, \dots, N, n_i = \sum_{k=0}^m r_{ik}$

確率が説明変数の関数として変化する

$$\Pr(y_i = A_k | \mathbf{x}_i) = \Pr(z_{ik} = 1 | \mathbf{x}_i) = \pi_k(\mathbf{x}_i)$$

確率のモデル

$$\pi_k(\mathbf{x}_i) = \frac{g_k(\mathbf{x}_i | \boldsymbol{\xi})}{\sum_{k'=0}^m g_{k'}(\mathbf{x}_i | \boldsymbol{\xi})}$$

多項ロジットモデル

$$\pi_k = \pi_k(A_k) = \frac{g(A_k | \boldsymbol{\xi})}{\sum_{k=0}^m g(A_k | \boldsymbol{\xi})}$$

$$g_k(\mathbf{x}_i | \boldsymbol{\xi}) = \exp(\mathbf{x}_i' \boldsymbol{\beta}_k + c_k)$$

0-3カテゴリカルデータの回帰分析

18

確率のモデル

$$\pi_k(\mathbf{x}_i) = \frac{g_k(\mathbf{x}_i | \boldsymbol{\xi})}{\sum_{k'=0}^m g_{k'}(\mathbf{x}_i | \boldsymbol{\xi})}$$

多項ロジットモデル

$$g_k(\mathbf{x}_i | \boldsymbol{\xi}) = \exp(\mathbf{x}_i' \boldsymbol{\beta}_k + c_k)$$

尤度関数

$$L(\boldsymbol{\xi}) = \prod_{i=1}^n \prod_{k=0}^m \pi_k(\mathbf{x}_i | \boldsymbol{\xi})^{z_{ik}} = \prod_{i=1}^n \prod_{k=0}^m \pi_k(\mathbf{x}_i | \boldsymbol{\xi})^{r_{ik}}$$

対数尤度関数

$$\ln L(\boldsymbol{\xi}) = \sum_{i=1}^n \sum_{k=0}^m r_{ik} \log \pi_k(\mathbf{x}_i | \boldsymbol{\xi})$$

0-3カテゴリカルデータの回帰分析

19

● Fisher のスコア法によるパラメタの推定

対数尤度関数のパラメタに関する一次偏微分

$$\begin{aligned} \frac{\partial \ln L}{\partial \boldsymbol{\xi}} &= \sum_{i=1}^N \sum_{k=0}^m (r_{ij} - n_i \pi_k(\mathbf{x}_i | \boldsymbol{\xi})) \frac{\partial \ln g_k(\mathbf{x}_i | \boldsymbol{\xi})}{\partial \boldsymbol{\xi}} \\ &= \sum_{i=1}^N \sum_{k=0}^m \frac{(r_{ik} - n_i \pi_k(\mathbf{x}_i | \boldsymbol{\xi}))}{g_k(\mathbf{x}_i | \boldsymbol{\xi})} \frac{\partial g_k(\mathbf{x}_i | \boldsymbol{\xi})}{\partial \boldsymbol{\xi}} \end{aligned}$$

Fisher Information Matrix

$$\mathbf{H}(\boldsymbol{\xi}) = \boldsymbol{\xi} \left(\left(\frac{\partial \ln L}{\partial \boldsymbol{\xi}} \right) \left(\frac{\partial \ln L}{\partial \boldsymbol{\xi}} \right)' \right) = n \mathbf{S}(\boldsymbol{\xi})' (\text{Diag}(\boldsymbol{\pi}) - \boldsymbol{\pi} \boldsymbol{\pi}') \mathbf{S}(\boldsymbol{\xi})$$

ただし

$$\mathbf{S}(\boldsymbol{\xi}) = \frac{\partial \log g(\mathbf{x} | \boldsymbol{\xi})}{\partial \boldsymbol{\xi}} = \left\{ \frac{\partial \log g_k(\mathbf{x}_i | \boldsymbol{\xi})}{\partial \xi_\ell} \right\} = \left\{ \frac{1}{g_k(\mathbf{x}_i | \boldsymbol{\xi})} \frac{\partial g_k(\mathbf{x}_i | \boldsymbol{\xi})}{\partial \xi_\ell} \right\}$$

$i = 1, 2, \dots, N, k = 0, 1, \dots, m, \ell = 1, 2, \dots, \dim(\boldsymbol{\xi})$

0-3カテゴリカルデータの回帰分析

20

x が一次元の場合の例 m=3

| x | A_0 | A_1 | A_2 | A_3 | n | p_0 | p_1 | p_2 | p_3 |
|------|-----|-----|-----|-----|----|-------|-------|-------|-------|
| -4.0 | 0 | 0 | 0 | 0 | 0 | 0.988 | 0.011 | 0.000 | 0.000 |
| -3.6 | 0 | 0 | 0 | 0 | 0 | 0.979 | 0.020 | 0.000 | 0.000 |
| -3.2 | 0 | 0 | 0 | 0 | 0 | 0.962 | 0.037 | 0.000 | 0.000 |
| -2.8 | 1 | 1 | 0 | 0 | 2 | 0.934 | 0.065 | 0.000 | 0.000 |
| -2.4 | 4 | 0 | 0 | 0 | 4 | 0.886 | 0.112 | 0.001 | 0.000 |
| -2.0 | 10 | 1 | 0 | 0 | 11 | 0.808 | 0.186 | 0.005 | 0.000 |
| -1.6 | 16 | 5 | 1 | 0 | 22 | 0.694 | 0.289 | 0.015 | 0.000 |
| -1.2 | 22 | 14 | 3 | 0 | 39 | 0.543 | 0.411 | 0.045 | 0.000 |
| -0.8 | 18 | 31 | 9 | 0 | 58 | 0.373 | 0.512 | 0.113 | 0.000 |
| -0.4 | 16 | 36 | 23 | 0 | 75 | 0.216 | 0.540 | 0.241 | 0.001 |
| 0.0 | 6 | 36 | 36 | 3 | 81 | 0.103 | 0.468 | 0.421 | 0.006 |
| 0.4 | 2 | 28 | 42 | 2 | 74 | 0.040 | 0.333 | 0.601 | 0.024 |
| 0.8 | 0 | 13 | 39 | 6 | 58 | 0.013 | 0.196 | 0.713 | 0.077 |
| 1.2 | 0 | 6 | 29 | 4 | 39 | 0.003 | 0.095 | 0.696 | 0.204 |
| 1.6 | 0 | 1 | 14 | 7 | 22 | 0.000 | 0.036 | 0.535 | 0.427 |
| 2.0 | 0 | 0 | 7 | 4 | 11 | 0.000 | 0.010 | 0.312 | 0.676 |
| 2.4 | 0 | 0 | 1 | 3 | 4 | 0.000 | 0.002 | 0.145 | 0.852 |
| 2.8 | 0 | 0 | 0 | 2 | 2 | 0.000 | 0.000 | 0.059 | 0.940 |
| 3.2 | 0 | 0 | 0 | 0 | 0 | 0.000 | 0.000 | 0.022 | 0.977 |
| 3.6 | 0 | 0 | 0 | 0 | 0 | 0.000 | 0.000 | 0.008 | 0.991 |
| 4.0 | 0 | 0 | 0 | 0 | 0 | 0.000 | 0.000 | 0.003 | 0.996 |

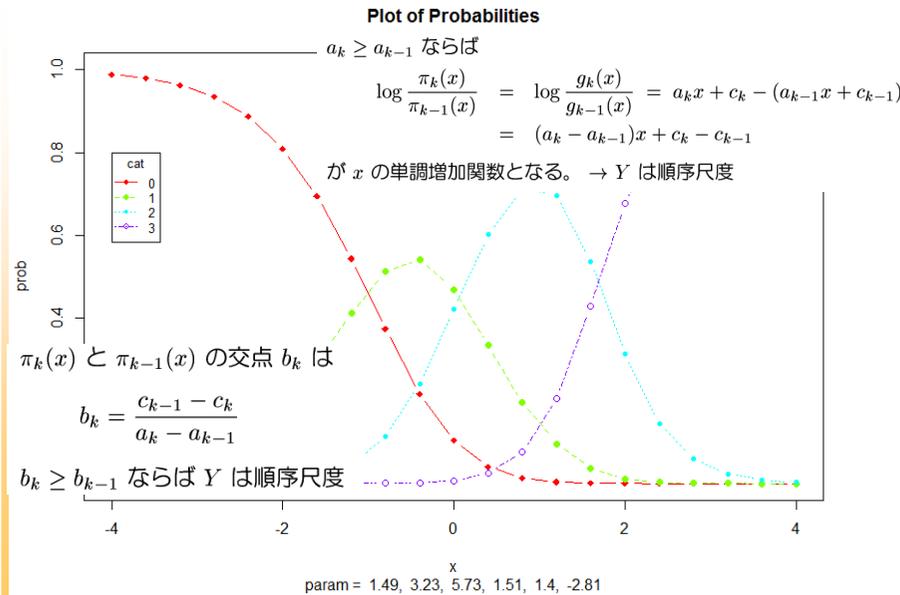
$$g(x_i | \boldsymbol{\xi}) = \exp(a_k x_i + c_k)$$

$$a_0 = 0 \quad c_0 = 0$$

$$a_1 = 1.489 \quad c_1 = 1.508$$

$$a_2 = 3.234 \quad c_2 = 1.401$$

$$a_3 = 5.728 \quad c_3 = -2.814$$



項目反応理論に関するいくつかの話題

1. 項目パラメタの推定 23

$P_{jk}(\theta)$ を θ を項目 j のカテゴリ k の項目カテゴリ反応関数 (ICRF) とする。

$$j = 1, 2, \dots, p, \quad k = 0, 1, 2, \dots, m_j$$

U_{ijk} を、個人 i が項目 j に於いて第 k 番目の得点を取った時に 1 となる変数とする。

θ を連続量と仮定すると、項目パラメタの周辺尤度関数は

$$mL(\Xi) = \prod_{i=1}^n \int_{\Theta} \prod_{j=1}^p \prod_{k=0}^{m_j} P_{jk}(\theta | \xi_j)^{u_{ijk}} h(\theta | \rho) d\theta$$

と書ける。 $h(\theta | \rho)$ はパラメタ ρ を持つ正規分布の pdf
 θ を $\theta_q, q = 1, 2, \dots, Q$, の離散値を取る変数
 と仮定すると、項目パラメタの周辺尤度関数は

$$mL(\Xi) = \prod_{i=1}^n \sum_{q=1}^Q h(\theta_q | \rho) \prod_{j=1}^p \prod_{k=0}^{m_j} P_{jk}(\theta_q | \xi_j)^{u_{ijk}}$$

ただし、 $\Pr(\Theta = \theta_q) = h(\theta_q | \rho) \propto \exp(-0.5(\theta_q - \mu)^2 / \sigma^2)$

1. 項目パラメタの推定

θ が離散の場合の EM アルゴリズム

E-step: データ U を与えた時の

$$\theta^* = (\theta_1^*, \theta_2^*, \dots, \theta_Q^*)$$

の条件付き分布は多項分布

$$\theta^* | \mathbf{u}_i \sim MN((\theta_1, \theta_2, \dots, \theta_Q), \mathbf{h}_i)$$

ただし

$$\mathbf{h}_i = (h_{i1}, h_{i2}, \dots, h_{iQ})$$

$$h_{iq} = \frac{\prod_{j=1}^p \prod_{k=0}^{m_j} P_{jk}(\theta_q | \xi_j)^{u_{ijk}} h(\theta_q | \rho)}{\sum_{q'=1}^Q \prod_{j=1}^p \prod_{k=0}^{m_j} P_{jk}(\theta_{q'} | \xi_j)^{u_{ijk}} h(\theta_{q'} | \rho)}$$

したがって

$$\mathcal{E}(\theta^* | \mathbf{u}_i) = \mathbf{h}_i, \quad \mathcal{E}(\theta_q^* | \mathbf{u}_i) = h_{iq},$$

1. 項目パラメタの推定

25

期待対数完全データ尤度

$$\begin{aligned} \varepsilon \ln L(\Lambda, \rho) &= \sum_{j=1}^p \sum_{q=1}^Q \sum_{k=0}^{m_j} \left(\sum_{i=1}^N h_{iq} u_{ijk} \right) \log P_{jk}(\theta_q | \xi_j) \\ &+ \sum_{q=1}^Q \left(\sum_{i=1}^N h_{iq} \right) \log h(\theta_q | \rho) \\ h(\theta_q | \mu, \sigma) &= \frac{\exp(-0.5(\theta_q - \mu)^2 / \sigma^2)}{\sum_{q'=1}^Q \exp(-0.5(\theta_{q'} - \mu)^2 / \sigma^2)} \end{aligned}$$

多項ロジットの対数尤度関数

$$\ln L(\xi) = \sum_{i=1}^n \sum_{k=0}^m r_{ik} \log \pi_k(\mathbf{x}_i | \xi)$$

数値カテゴリを持つ多項分布の対数尤度関数

$$\ln L(\xi) = \sum_{k=1}^m f_k \log \left(\frac{g(A_k | \xi)}{\sum_{k'=1}^m g(A_{k'} | \xi)} \right)$$

1. 項目パラメタの推定

26

項目カテゴリ反応関数 ICRF

3PLM: $m_j = 1$

$$\begin{aligned} P_{j1}(\theta) &= c_j + \frac{1 - c_j}{1 + \exp(-1.7a_j(\theta - b_j))} \\ P_{j0}(\theta) &= 1 - P_{j1}(\theta) \end{aligned}$$

Graded Response Model

$$\begin{aligned} P_{jk}(\theta) &= P_{j,k}^+(\theta) - P_{j,k+1}^+(\theta), \quad k = 0, 1, 2, \dots, m_j \\ P_{j,k}^+(\theta) &= \frac{1}{1 + \exp(-1.7a_j(\theta - b_{jk}))} \\ P_{j0}^+(\theta) &= 1, \quad P_{j,m_j+1}^+(\theta) = 0 \end{aligned}$$

1. 項目パラメタの推定

27

項目カテゴリ反応関数 ICRF

Nominal Response Model (NRM)

$$\begin{aligned} P_{jk}(\theta) &= \frac{\exp(a_{jk}\theta + c_{jk})}{\sum_{k'=0}^{m_j} \exp(a_{jk'}\theta + c_{jk'})}, \quad a_{j0} = c_{j0} = 0 \\ &= \frac{\exp(a_{jk}\theta + c_{jk})}{1 + \sum_{k'=1}^{m_j} \exp(a_{jk'}\theta + c_{jk'})}, \quad P_{j0}(\theta) = 1 - \sum_{k=1}^{m_j} P_{jk}(\theta) \end{aligned}$$

2PLM as a special case of NRM

$$m_j = 1, \quad a_{j1} = 1.7a_j, \quad c_{j1} = -1.7a_j b_j$$

Generalized Partial Credit Model as a special case of NRM

$$a_{jk} = 1.7a_j \times k$$

1. 項目パラメタの推定

28

Fisher のスコア法を用いた場合には

$$\frac{\partial \log P_{jk}(\theta | \xi_j)}{\partial \xi_j}$$

のみが必要。

2 順序カテゴリの取り扱い

29

Nominal Response Model (NRM)

$$P_{jk}(\theta) = \frac{\exp(a_{jk}\theta + c_{jk})}{\sum_{k'=0}^{m_j} \exp(a_{jk'}\theta + c_{jk'})}, \quad a_{j0} = c_{j0} = 0$$

$a_{jk} \geq a_{j,k-1}$ ならば

$$\begin{aligned} \log \frac{P_{jk}(\theta)}{P_{j,k-1}(\theta)} &= a_{jk}\theta + c_{jk} - (a_{j,k-1}\theta + c_{j,k-1}) \\ &= (a_{jk} - a_{j,k-1})\theta + c_{jk} - c_{j,k-1} \end{aligned}$$

が θ の単調増加関数となる。 → 項目 j は順序尺度

$P_{jk}(\theta)$ と $P_{j,k-1}(\theta)$ の交点 b_{jk} は

$$b_{jk} = \frac{c_{j,k-1} - c_{jk}}{a_{jk} - a_{j,k-1}}$$

$b_{jk} \geq b_{j,k-1}$ ならば 項目 j は順序尺度

2 順序カテゴリの取り扱い

30

New Ordered Model

$$P_{jk}(\theta) = \frac{\exp\left(a_{jk}\theta - \sum_{h=1}^k (a_{jh} - a_{j,h-1})b_{jh}\right)}{\sum_{k=0}^{m_j} \exp\left(a_{jk}\theta - \sum_{h=1}^k (a_{jh} - a_{j,h-1})b_{jh}\right)}$$

$$a_{jk} \geq a_{j,k-1} \quad \text{and} \quad b_{jk} \geq b_{j,k-1}$$

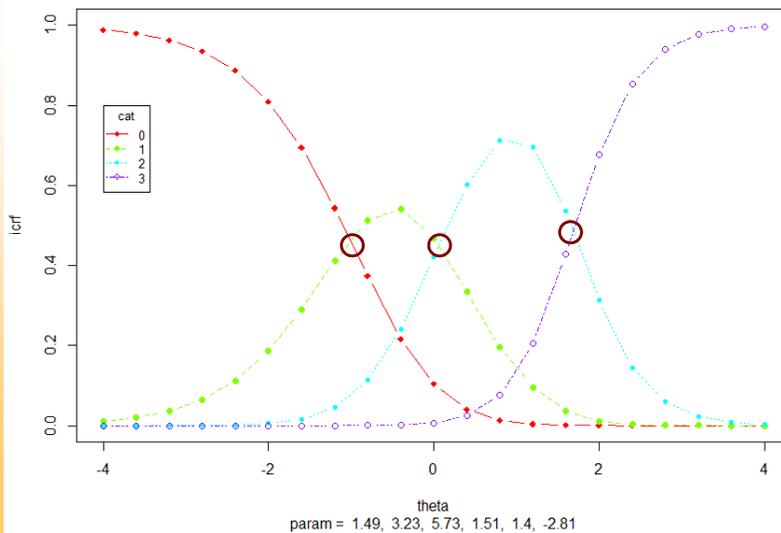
Partial Credit Type

$$P_{jk}(\theta) = \frac{\exp\left(a_{jk}\theta - \sum_{h=1}^k b_{jh}\right)}{\sum_{k'=0}^{m_j} \exp\left(a_{jk'}\theta - \sum_{h=1}^{k'} b_{jh}\right)}$$

2 順序カテゴリの取り扱い

31

Plot of ICRF of Q1 (type = N, ncat= 4)



3. 重み付き得点からの θ の推定

32

重み付き得点

$$X = \sum_{j=1}^p w_j \sum_{k=0}^{m_j} v_{jk} U_{jk}, \quad 0 \leq X \leq \sum_{j=1}^p w_j v_{jm_j}$$

から θ を推定することを考える。

このためには X を与えた時の θ の事後分布

$$\Pr(\Theta = \theta | X = x) = \frac{\Pr(X = x | \Theta = \theta) \Pr(\Theta = \theta)}{\sum_{\theta} \Pr(X = x | \Theta = \theta) \Pr(\Theta = \theta)}$$

を計算し、その事後平均等を用いれば良い。

ここで $\Pr(X = x | \Theta = \theta)$ は、

$$U_j | \theta \sim MN((v_{j0}, v_{j1}, v_{j2}, \dots, v_{j,m_j}), \mathbf{P}_j(\theta))$$

であり、また、項目反応は局所独立であるから、

p 個の独立な数値化された多項分布の w_j による重み付きの分布となる。

3. 重み付き得点からの θ の推定 33

最適な重みは何か？

十分統計量で重みを付ければ良い！

NRM の十分統計量は

$$z = \sum_{j=1}^p \sum_{k=0}^{m_j} u_{kj} a_{kj}$$

なぜなら

$$\begin{aligned} \log L &= \sum_{j=1}^p \sum_{q=0}^{m_j} u_{qj} \log P_{kj}(\theta) & \sum_{k=0}^{m_j} u_{kj} &= 1 \\ &= \sum_{j=1}^p \sum_{q=0}^{m_j} u_{qj} \left(a_{qj}\theta + c_{qj} - \log \sum_{q=0}^{m_j} \exp(a_{qj}\theta + c_{qj}) \right) \\ &= - \sum_{j=1}^p \log \left(\sum_{q=0}^{m_j} \exp(a_{qj}\theta + c_{qj}) \right) \sum_{k=0}^{m_j} u_{kj} + \sum_{j=1}^p \sum_{k=0}^{m_j} c_{kj} u_{kj} + \theta \sum_{j=1}^p \sum_{k=0}^{m_j} u_{kj} a_{kj} \\ &= - \sum_{j=1}^p \log \left(\sum_{q=0}^{m_j} \exp(a_{qj}\theta + c_{qj}) \right) + \sum_{j=1}^p \sum_{k=0}^{m_j} c_{kj} u_{kj} + \theta \sum_{j=1}^p \sum_{k=0}^{m_j} u_{kj} a_{kj} \end{aligned}$$

3. 重み付き得点からの θ の推定 35

3PLM と Graded Response Model には十分統計量が見あたらない。

重み付き得点で θ を推定する時の情報量の期待値を最大にする重み → 大局的最適重み

重みが θ に依存しても良いのなら

局所的最適重み basic function (Samejima, 1969, p24)

$$v_{jk} = v_{jk}(\theta) = \frac{P'_{jk}(\theta)}{P_{jk}(\theta)}$$

3. 重み付き得点からの θ の推定 34

最適重み

重み付き得点

$$\begin{aligned} X &= \sum_{j=1}^p w_j \sum_{k=0}^{m_j} v_{jk} U_{jk}, \quad 0 \leq X \leq \sum_{j=1}^p w_j v_{jm_j} \\ &= \sum_{j=1}^p \sum_{k=0}^{m_j} v_{jk} U_{jk}, \quad 0 \leq X \leq \sum_{j=1}^p v_{jm_j} \end{aligned}$$

2PLM

$$v_{j0} = 0, \quad v_{j1} \propto a_j$$

Generalized Partial Credit Model

$$v_{jk} \propto a_j \times k, \quad k = 0, 1, \dots, m_j$$

重みは、加算的また乗算的不定性を持つ。

4. 独立に推定された項目パラメタの等化 36

項目反応モデル

3PLM: $m_j = 1$

$$\begin{aligned} P_{j1}(\theta) &= c_j + \frac{1 - c_j}{1 + \exp(-1.7a_j(\theta - b_j))} \\ P_{j0}(\theta) &= 1 - P_{j1}(\theta) \end{aligned}$$

Graded Response Model

$$\begin{aligned} P_{jk}(\theta) &= P_{j,k}^+(\theta) - P_{j,k+1}^+(\theta), \quad k = 0, 1, 2, \dots, m_j \\ P_{j,k}^+(\theta) &= \frac{1}{1 + \exp(-1.7a_j(\theta - b_{jk}))} \\ P_{j0}^+(\theta) &= 1, \quad P_{j,m_j+1}^+(\theta) = 0 \end{aligned}$$

Generalized Partial Credit Model

$$P_{jk}(\theta) = \frac{\exp 1.7 \left(\sum_{h=0}^k (a_j(\theta - b_{jh})) \right)}{\sum_{k'=0}^{m_j} \exp 1.7 \left(\sum_{h=0}^{k'} (a_j(\theta - b_{jh})) \right)}, \quad k = 0, 1, 2, \dots, m_j$$

4. 独立に推定された項目パラメタの等化 37

共通尺度上のパラメタの値

$$\xi_j = \{a_j, b_j\}, j = 1, 2, \dots, p, g = 1, 2, \dots, G$$

第 g 番目の尺度上のパラメタの値

$$\xi_j^{(g)} = \{a_j^{(g)}, b_j^{(g)}\}, j = 1, 2, \dots, p, g = 1, 2, \dots, G$$

個別尺度と共通尺度： 原点と単位の不定性

$$\theta^{(g)} = u_g + v_g \theta, \quad g = 1, 2, \dots, G$$

パラメタ値の関係

$$a_j^{(g)} = \frac{1}{v_g} a_j \quad \text{and} \quad b_j^{(g)} = u_g + v_g b_j, \quad j = 1, 2, \dots, p$$

4. 独立に推定された項目パラメタの等化 38

b パラメタにのみ着目

$$b_j^{(g)} = u_g + v_g b_j, \quad j = 1, 2, \dots, p$$

第 g 番目の尺度上のパラメタの推定値

$$\widehat{\xi}_j^{(g)} = \{\widehat{a}_j^{(g)}, \widehat{b}_j^{(g)}\}, j = 1, 2, \dots, p, \quad g = 1, 2, \dots, G$$

因子分析

$$\widehat{b}_j^{(g)} = u_g + v_g b_j + e_j$$

4. 独立に推定された項目パラメタの等化 39

因子分析： cal-a

$$\widehat{b}_j^{(g)} = u_g + v_g b_j + e_j$$

ICRF メトリックの利用： cal-r

$$\begin{aligned} P_{jk}(\theta | \widehat{\xi}_j^{(g)}) &= P_{jk}(\theta | \xi_j^{(g)}) + e_j \\ &= P_{jk}(q_g + r_g \theta | \xi_j) + e_j \end{aligned}$$

ただし

$$q_g = -\frac{u_g}{v_g}, \quad r_g = \frac{1}{v_g}$$

4. 独立に推定された項目パラメタの等化 40

● 最小2乗解

最小2乗基準： cal-a

$$RSS_A = \sum_{g=1}^G \sum_{j \in g} \sum_{k=1}^{m_j} \left(\widehat{b}_{jk}^{(g)} - (u_g + v_g b_{jk}) \right)^2$$

最小2乗基準： cal-r

$$RSS_R = \sum_{g=1}^G \sum_{j \in g} \sum_{k=1}^{m_j} \sum_{q=1}^Q \left(P_{jk}(\theta_q | \widehat{\xi}_j^{(g)}) - P_{jk}(q_g + r_g \theta_q | \xi_j) \right)^2 h_g(\theta_q | \mu_g, \sigma_g)$$

$$\mu_g = 0, \quad \sigma_g = 1, \quad g = 1, 2, \dots, G$$

ご静聴、有難うございました。

mayekawa@nifty.com
www.ms.hum.titech.ac.jp