

高次元データにおける平均ベクトルの検定

¹ 藤本 翔太, ¹ 狩野 裕, ² Muni S. Srivastava



¹ 大阪大学大学院基礎工学研究科, ² Department of Statistics, University of Toronto

Introduction

✓ 設定

$\mathbf{X}_p^{(1)}, \dots, \mathbf{X}_p^{(n)}$ i.i.d. $N_p(\boldsymbol{\mu}_p, \boldsymbol{\Sigma}_p)$

$$\bar{\mathbf{X}}_{n,p} = \frac{1}{n} \sum_{i=1}^n \mathbf{X}_p^{(i)}, \quad \mathbf{S}_{n,p} = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{X}_p^{(i)} - \bar{\mathbf{X}}_{n,p})(\mathbf{X}_p^{(i)} - \bar{\mathbf{X}}_{n,p})^T$$

$$H_0 : \boldsymbol{\mu}_p = \mathbf{0} \text{ vs } H_1 : \boldsymbol{\mu}_p \neq \mathbf{0}$$

✓ 高次元データ ($n \leq p$)

$$T = n \bar{\mathbf{X}}_{n,p}^T \mathbf{S}_{n,p}^{-1} \bar{\mathbf{X}}_{n,p} \implies \text{定義されない}$$

✓ 高次元データにも対応可能な検定統計量

Dempster(1958) Bai and Saranadasa(1996)

$$T_D = n \bar{\mathbf{X}}_{n,p}^T \bar{\mathbf{X}}_{n,p} / \text{tr} \mathbf{S}_{n,p} \quad T_{BS} = n \bar{\mathbf{X}}_{n,p}^T \bar{\mathbf{X}}_{n,p} - \text{tr} \mathbf{S}_{n,p}$$

✓ $H_0, (n, p) \rightarrow \infty$ における漸近正規性に次の条件を要求

$$(A) \text{tr} \boldsymbol{\Sigma}_p^4 = o\{(\text{tr} \boldsymbol{\Sigma}_p^2)^2\}$$

✓ かなり強い条件 ($\boldsymbol{\Sigma}_p$ がほとんど単位行列)

✓ Fujimoto et al.(2010, Submitted)

漸近分布の形状が $\boldsymbol{\Sigma}_p$ に依存して変化

$$\tilde{T}_{BS} = \frac{T_{BS}}{\sqrt{2 \text{tr} \boldsymbol{\Sigma}_p^2}} \xrightarrow{d} \Phi_{\{\boldsymbol{\Sigma}_p\}}, \quad (n, p) \rightarrow \infty$$

$\Phi_{\{\boldsymbol{\Sigma}_p\}} \Rightarrow \text{Normal, Chi-Square, Convolution}$

定理 1 ($\text{tr} \boldsymbol{\Sigma}_p^2$ の推定量): 任意の $\varepsilon > 0$ に対して,

$$\lim_{n \rightarrow \infty} \sup_p P \left(\left| \frac{\hat{a}}{\text{tr} \boldsymbol{\Sigma}_p^2} - 1 \right| > \varepsilon \right) = 0,$$

$$\text{where } \hat{a} = \frac{(n-1)^2}{(n+1)(n-2)} \left[\text{tr} \mathbf{S}_{n,p}^2 - \frac{1}{n-1} (\text{tr} \mathbf{S}_{n,p})^2 \right]$$


✓ Toy Model

$$\boldsymbol{\Sigma}_p = (1 - \rho_p) \mathbf{I}_p + \rho_p \mathbf{1}_p \mathbf{1}_p^T, \quad \rho_p = p^{-\alpha} \quad (0 < \alpha < 1)$$

$$0 < \alpha < 1/2 \Rightarrow \tilde{T}_{BS} \xrightarrow{d} (\chi_1^2 - 1) / \sqrt{2}$$

$$\alpha = 1/2 \Rightarrow \tilde{T}_{BS} \xrightarrow{d} \frac{1}{\sqrt{2}} N(0, 1) + \frac{1}{\sqrt{2}} \frac{\chi_1^2 - 1}{\sqrt{2}}$$

$$1/2 < \alpha < 1 \Rightarrow \tilde{T}_{BS} \xrightarrow{d} N(0, 1)$$



$n = 100, p = 200$, 繰り返し回数 10,000

赤: $\alpha = 0.1 - 0.4$, 緑: $\alpha = 0.5$, 青: $\alpha = 0.6 - 0.9$

Proposed Test

✓ 任意の $\boldsymbol{\Sigma}_p$ に対して漸近正規する検定統計量の提案

$$T_{M_n} = \text{tr} \mathbf{X}_{n,p}^T \mathbf{M}_n \mathbf{X}_{n,p}, \quad \mathbf{X}_{n,p} = (\mathbf{X}_p^{(1)}, \dots, \mathbf{X}_p^{(n)})^T$$

✓ $n \times n$ 行列 \mathbf{M}_n は次を満たすようにとる

$$(B) \text{tr} \mathbf{M}_n = 0; \mathbf{1}_n^T \mathbf{M}_n \mathbf{1}_n \neq 0; \text{tr} \mathbf{M}_n^2 \neq 0; \text{tr} \mathbf{M}_n^4 = o\{(\text{tr} \mathbf{M}_n^2)^2\}$$

✓ Moments

$$E(T_{M_n}) = (\mathbf{1}_n^T \mathbf{M}_n \mathbf{1}_n) \boldsymbol{\mu}_p^T \boldsymbol{\mu}_p + \text{tr} \mathbf{M}_n \text{tr} \boldsymbol{\Sigma}_p$$

$$\text{Var}(T_{M_n}) = 2 \text{tr} \mathbf{M}_n^2 \text{tr} \boldsymbol{\Sigma}_p^2 + 4 (\mathbf{1}_n^T \mathbf{M}_n^2 \mathbf{1}_n) \boldsymbol{\mu}_p^T \boldsymbol{\Sigma}_p \boldsymbol{\mu}_p$$

定理 2 条件 (B) を仮定. H_0 の下, 以下が成立つ:

$$\tilde{T}_{M_n} = \frac{T_{M_n}}{\sqrt{2 \text{tr} \mathbf{M}_n^2 \text{tr} \boldsymbol{\Sigma}_p^2}} \xrightarrow{d} N(0, 1), \quad (n, p) \rightarrow \infty$$

✓ なぜ漸近正規性に $\boldsymbol{\Sigma}_p$ の条件を要求しないか?

Lyapunov 条件
($\delta = 2$)

$$\implies 15 \frac{\text{tr} \mathbf{M}_n^4}{(\text{tr} \mathbf{M}_n^2)^2} \frac{\text{tr} \boldsymbol{\Sigma}_p^4}{(\text{tr} \boldsymbol{\Sigma}_p^2)^2}$$

0 に収束


✓ 行列 \mathbf{M}_n の候補

$$\mathbf{M}_n^{(1)} = (m_{ij}) \text{ with } m_{ii} = 0 \text{ and } m_{ij} = \rho^{|i-j|} \quad (|\rho| < 1)$$

$$\mathbf{M}_n^{(2)} = (m_{|i-j|}) \text{ with } m_0 = 0 \text{ and } \lim_{n \rightarrow \infty} \sum_{k=1}^{n-1} |m_k| < \infty$$

✓ Simulation (左と同じデータを使用)

$$\mathbf{M}_n = \mathbf{M}_n^{(1)}, \quad \text{tr} \mathbf{M}_n^4 / (\text{tr} \mathbf{M}_n^2)^2 = 0.02$$



Further Works

✓ 漸近正規性を保ちながら検出力も大きくする

$$\max_{\mathbf{M}_n} \frac{\mathbf{1}_n^T \mathbf{M}_n \mathbf{1}_n}{\sqrt{\text{tr} \mathbf{M}_n^2}} \quad \text{subject to} \quad \frac{\text{tr} \mathbf{M}_n^4}{(\text{tr} \mathbf{M}_n^2)^2} \leq c$$

✓ NOTE

$$\text{制約条件なしの最適化} \implies \tilde{T}_{M_n} \approx \tilde{T}_{BS}$$

✓ 問題点と今後の課題

✓ T_{M_n} の取る値はデータの並び替えに依存

\implies Random Permutation Sample を使って客観化