

仮説に制約条件がある場合の

Bivariate Sign Test

九大理学部 野間口謙太郎

Hodges ( 1955 AMS ) は 1 次元 data に対する sign 検定を union-intersection principle を用いて、2 次元 data に対して拡張した。これがいわゆる bivariate sign test である。彼の考え方は parameter space に cone-制約条件が付いた場合でも適用可能である。

$R^2$  上の分布関数  $F$  を、原点を境界に持つ任意の half space 上の確率が常に  $1/2$  であるものとする。  $C$  を  $R^2$  の真の closed convex cone とする。一般性を失わずに一つの edge を  $x$ -軸に取ってよい。さらにもう一つの edge を vector  $L$  方向とする。ここで vector の argument 関数  $\arg(\cdot)$  を通常 argument 関数を  $\pi$  で割ったものとする。例えば  $\arg((0,1)')$  は  $1/2$  となる。これを用いて  $C$  は  $\{x \in R^2 \mid 0 \leq \arg(x) \leq \arg(L)\}$  とかける。このとき sample  $X_1, X_2, \dots, X_n \sim F(x - \theta)$  に基づいて、

仮説検定問題  $H_0: \theta = 0$  vs.  $H_1: \theta \in C - \{0\}$  に対する、Hodges 流の検定統計量  $T_n$  を提案したい。ここでの取り扱い方は Joffe & Klotz (1962 AMS) に従っていて、この統計量の exact 分布、漸近分布を求め、Bahadur efficiency を計算する。

まず Hodges が、どのように考えたか、みてみたい。彼は

(1) 任意の  $\mu \in R^2$  に対して  $H_0(\mu) \equiv H_0$ ,  $H_1(\mu)$

$\equiv \{\mu\}$  と置き、仮説を次のように分解した。

$$H_0 = \bigcap_{\mu \in R^2} H_0(\mu), \quad H_1 = \bigcup_{\mu \in R^2} H_1(\mu)$$

(2) 次ぎに、部分仮説検定問題  $H_0(\mu)$  vs.  $H_1(\mu)$

に対する検定統計量として  $\mu'X_1, \dots, \mu'X_n$  を

用いた sign 検定を採用する。つまり

$$T_\mu \equiv (1/n) \sum_{i=1}^n I[\mu'X_i > 0]$$

を用いる。

(3) union-intersection principle の考え方により本来

の検定統計量として次の

$$T \equiv \sup_{\mu \neq 0} T_\mu$$

を採用する。  $T$  が大きいとき  $H_0$  が棄却されることになる。

これが、Hodges のとった approach である。これになら  
 って制約条件付の場合も同様にしたいのであるが、よくなが  
 めると (2) において必ずしも  $X_i$  と対立仮説の方向  $\mu$  との内  
 積をとる必要はないということが解る。内積をとる相手と  
 してはもっと良い方向  $\nu$  がありうる。次の例を考えてみる。  
 各  $X_i$  が、elliptical 分布に従っているとする。つまり  $X_i$   
 $= V_i \Sigma^{1/2} U_i$  という形をしているとしよう。ただし、 $\Sigma$  :  
 positive definite matrix、 $U_i$  : 単位円周上の一様分布に  
 従う r.v.、 $V_i$  : 正の r.v. とする。このとき、 $H_0(\mu)$   
 vs.  $H_1(\mu)$  に対する sign 検定の中で most powerful な  
 方向は、

$$\begin{aligned} P(\nu' X_i \geq 0 \mid \theta = \mu) \\ &= P(\nu'(V_i \Sigma^{1/2} U_i + \mu) \geq 0) \\ &= E(P(\nu' \Sigma^{1/2} U_i \geq V_i^{-1} \nu' \mu \mid V_i)) \end{aligned}$$

を最大にするものであるから、 $\nu = \Sigma^{-1} \mu$  とすれば良いこと  
 がわかる。勿論  $\Sigma$  は未知であるから直接にこれとの内積は  
 とれないのであるが、 $\Sigma = I$  の場合は  $\mu$  との内積をとれば良  
 いのだから、data  $X_i$  をなるべく spherical 分布に従うよう  
 に変換した後で対立仮説方向との内積を取ることにすれば良  
 い。この考え方により次ぎの検定統計量を提案する。

(1) 各 data の原点からの距離を一定にする。

$$Y_i \equiv X_i / |X_i|$$

(2) 第3、4象限の data は原点に関して対称な点に移す。

$$Z_i \equiv \begin{cases} Y_i & \text{if } 0 \leq \arg(Y_i) < \pi \\ -Y_i & \text{otherwise} \end{cases}$$

(3)  $Z_i$ をその argument の順序を守りながら第1象限の半円周上に等間隔に並べる。 $Z_i$ に対応するものを  $U_i$ とおく。つまり  $Z_i$ の argument が  $j$ 番目ならば  $\arg(U_i) = (j/n) - (1/2n)$ であるようにとる。このとき  $\rho \equiv P(X_i \in C \cup (-C))$ 、この一致推定量を

$$\hat{\rho} \equiv (1/n) \sum_{i=1}^n I[Z_i \in C]$$

とおき, vector  $L'$ , cone  $C'$  を次のように定義する。

$$\arg(L') = \hat{\rho},$$

$$C' \equiv \{x \mid 0 \leq \arg(x) \leq \arg(L')\}.$$

$L'$ と  $C'$  は、 $Z_i$ から  $U_i$ への変換に伴う  $L$ と  $C$ の変換に対応する。任意の  $v \in R^2$  に対しても同様に、 $v' \in R^2$  を定義する。

(4) (2)において対称な点に移したものは再度対称な点に戻す。

$$V_i \equiv \begin{cases} U_i & \text{if } Z_i = Y_i \\ -U_i & \text{otherwise} \end{cases}$$

$$(5) \quad R_t \equiv \{ X \in R^2 \mid -1/2 < (\arg(X) - t) \bmod 2 \leq 1/2 \}$$

と置き、

$$T_n(t) \equiv \sum_{i=1}^n I [V_i \in R_t]$$

を定義して、検定統計量として

$$T_n \equiv \sup_{0 \leq t \leq \rho} T_n(t)$$

を採用する。  $\alpha$ -point を  $k_\alpha(\rho)$  と置くと、検定は

$$T_n \geq n/2 + \sqrt{n} k_\alpha(\hat{\rho})$$

のとき、 $H_0$  を棄却する事になる。

なお、制約条件が無い場合には optimal な方向などというようなものを考える必要はない。なぜならば、全ての方向との内積をとってその sup をみるのだから、結局 optimal な方向との内積も考慮されていることになるからである。

### \*\*\* EXACT 分布 の 計算 \*\*\*

まず、 $C = \{ x \in R^2 \mid 0 \leq \arg(x) \leq 1 \}$  の場合を考えてみる。この場合の統計量を特別に  $T_n^*$  と書くことにする。  $T_n(i/n) - T_n(0)$ ,  $i=0, 1, 2, \dots, n$  が random walk であることは容易に確かめることができるので、 $S_i$ ,  $i$

$= 0, 1, 2, \dots, n$  を random walk とするとき

$$\begin{aligned} P(2(T_n^* - n/2) \leq t) \\ = P(2 \sup_{0 \leq i \leq n} S_i - S_n \leq t) \end{aligned}$$

と書ける。ところで、鏡像原理によると

$$\begin{aligned} P(S_1 < a, \dots, S_n < a, S_n = b) \\ = P(S_n = b) - P(S_n = 2a - b) \end{aligned}$$

であるから、 $n, t$  が偶数のとき、

$$\begin{aligned} P(2(T_n^* - n/2) \leq t) \\ = \sum_{i=-t}^t P(S_j < (t+i)/2, j=1, \dots, n, S_n = i) \\ = P(-t \leq S_n \leq t) - (t+1)P(S_n = t+2) \end{aligned}$$

$n, t$  が奇数の場合も同様にして、

$$= P(-t \leq S_n \leq t) - tP(S_n = t+2)$$

を得る。

一般の  $C = \{X \in R^2 \mid 0 \leq \arg(X) \leq \arg(L)\}$  の場合は、 $C \cup (-C)$  に落ちた data の数  $N_0$  の条件付のもとで求められる。明らかに  $N_0 \sim B(n, \rho)$  であるが、 $N_0 = n_0$  が与えられたとき、 $\bigcap_{0 \leq t \leq \arg(L')} R_t$  に含まれる

data  $U_i$  は常に  $T_n$  に +1 として貢献するので、その数を  $Y_{n-n_0}$  と置く、 $R^2 - C \cup (-C)$  に含まれる  $n_0$  個の  $U_i$  に関

しては  $C = \{x \in R^2 \mid 0 \leq \arg(x) \leq 1\}$  の場合に考察したものと同様であるから  $T_{n_0}^*$  と書く。すると  $T_n = Y_{n-n_0} + T_{n_0}^*$  と表現でき、 $N_0 = n_0$  の条件付で、 $Y_{n-n_0} \perp T_{n_0}^*$ 、 $Y_{n-n_0}$  である。これより  $T_n$  の分布を求めるには、 $N_0$  が与えられたもとでの  $Y_{n-n_0}$  と  $T_{n_0}^*$  との convolution をとり、しかるのちに  $N_0$  の分布で mixture をとらなければならない。この計算は不可能とは言わないが、大変にうるさい。そこで、次ぎに漸近分布の計算をやってみる。

\*\*\* 漸 近 分 布 の 計 算 \*\*\*

まず  $T_n^*$  の漸近分布を求めてみる。exact 分布より  $n$  が偶数のとき、

$$\begin{aligned} P(2(T_n^* - n/2) \leq \sqrt{n}t) \\ = P(-[\sqrt{n}t] \leq S_n \leq [\sqrt{n}t]) \\ - ([\sqrt{n}t] + 1)P(S_n = [\sqrt{n}t] + 2) \end{aligned}$$

である。ただし  $[\sqrt{n}t]$  は  $\sqrt{n}t$  より小さい最大の偶数である。

また  $n$  が奇数の場合も同様であるから、これより  $n$  について極限をとって、次を得る。

$$\lim_{n \rightarrow \infty} P(2(T_n^* - n/2) \leq \sqrt{n}t)$$

$$= \Phi(t) - \Phi(-t) - t \phi(t)$$

ただし  $\Phi$ 、 $\phi$  はそれぞれ標準正規分布  $N(0,1)$  の分布関数と密度関数である。この極限分布は、 $Z$  を自由度3のカイ二乗分布に従うとするときの  $Z^2$  の従う分布に等しいので、これを  $\sqrt{\chi_3^2}$ 、この分布関数を  $G$  と書くことにする。また  $\sqrt{\rho}$   $Z$  の分布を  $\sqrt{\rho} \sqrt{\chi_3^2}$ 、 $N(0,1-\rho)$  を  $\sqrt{1-\rho} N(0,1)$ 、これらの convolution を  $\sqrt{1-\rho} N(0,1) + \sqrt{\rho} \sqrt{\chi_3^2}$ 、この分布関数を  $G_\rho$  と書くことにする。exact 分布の表現から、

$$2(T_n - n/2)/\sqrt{n} \underset{a}{\sim} \sqrt{1-\rho} N(0,1) + \sqrt{\rho} \sqrt{\chi_3^2}$$

となるのはすぐに解るのであるが、ここでは別の approach を試みてみよう。

$$(T_n - n/2)/\sqrt{n}$$

$$= \sup_{0 \leq t \leq \bar{\rho}} (T_n(t) - T_n(0))/\sqrt{n} - (T_n(1) - T_n(0))/2\sqrt{n}$$

と変形できるが、 $\{(T_n(t) - T_n(0))/\sqrt{n}, 0 \leq t \leq 1\}$  は process として Wiener process  $W_t$  に、 $\bar{\rho}$  は  $\rho$  に弱収束するので、これより

$$\begin{aligned} 2(T_n - n/2)/\sqrt{n} &\underset{a}{\sim} 2 \sup_{0 \leq t \leq \rho} W_t - W_1 \\ &= (2 \sup_{0 \leq t \leq \rho} W_t - W_\rho) + (W_\rho - W_1) \end{aligned}$$

を得る。明らかに第1項と第2項とは独立であり、第2項



は  $\sqrt{1-\rho} N(0,1)$  に従う。 よって、第1項が  $\sqrt{\rho} \sqrt{\chi^2_3}$  に従うことを示せばよい。 このために  $Bt \equiv W_{t\rho} / \sqrt{\rho}$ ,  $0 \leq t \leq 1$ ,  $(M, B) \equiv (\sup_{0 \leq t \leq 1} Bt, B_1)$  と定義する。

$Bt$  はまた Wiener process となり、この時の  $(M, B)$  の同時密度関数が次ぎで与えられる事はよく知られている。

$$f(m, b) = \begin{cases} \sqrt{2/\pi} (2m-b) \exp(-(2m-b)^2/2) & \text{if } m \geq 0, m \geq b \\ 0 & \text{otherwise} \end{cases}$$

これより  $2M - B = (2 \sup_{0 \leq t \leq \rho} Wt - W_\rho) / \sqrt{\rho}$  の密度関数は

$$\sqrt{2/\pi} t^2 \exp(-t^2/2)$$

と計算できる。 これは  $\sqrt{\chi^2_3}$  の密度関数である。

### \*\* Approximate Bahadur Efficiency の計算 \*\*

検定統計量  $S_n$  の Bahadur slope は、

(1)  $\theta = 0$  の下で、 $S_n$  はある確率変数  $S$  に弱収束し、

$S$  の分布関数を  $F_S$  と置くとき、

$$\log(1 - F_S(x)) = (-ax^2/2) (1 + o(1))$$

となり、

(2)  $\theta = \mu$  の下で、 $S_n / \sqrt{n}$  が  $b(\mu)$  に確率収束するとき、

$a(b(\mu))^2$  で与えられる。

ここでは  $S_n = (2/\sqrt{n})(T_n - n/2)$  と置く。さらに  $\theta = 0$  の下での分布を parameter  $(\Sigma, 0)$  の elliptical 分布として、 $\Sigma = I$  のときの  $X$ -座標の周辺分布を  $\Psi$  で表すことにする。

#### a の計算

$T_n$  の定義から明らかに、

$$T_n(0) \leq T_n \leq T_n^*$$

である。よって

$$\begin{aligned} (2/\sqrt{n})(T_n(0) - n/2) &\leq S_n \\ &\leq (2/\sqrt{n})(T_n^* - n/2) \end{aligned}$$

これより次ぎの stochastic larger 性を得る。

$$N(0,1) \underset{St.}{<} \sqrt{1-\rho} N(0,1) + \sqrt{\rho} \sqrt{\chi_3^2} \underset{St.}{<} \sqrt{\chi_3^2}$$

これは分布関数で書けば

$$\Phi(x) \geq G_\rho(x) \geq G(x)$$

となるが、

$$\log(1 - \Phi(x)) = (-x^2/2)(1 + o(1))$$

$$\log(1 - G(x)) = (-x^2/2)(1 + o(1))$$

が成り立つのは明らかだろうから、次がえられる。

$$\log(1 - G_p(x)) = (-x^2/2)(1 + o(1))$$

つまり  $a=1$  である。

### $b(\mu)$ の計算

これを求めるために、 $\nu'\mu > 0$  であり、 $\nu'Z_i > 0$  となる  $Z_i$  の個数が丁度  $[n/2]$  個となる様な方向  $\nu$  で、この長さが  $|\Sigma^{-1}\mu|$  に等しくなるものを  $\nu_n$  とおく。  $\mu \in C$  を変換した  $\mu' \in C'$  に対する  $R_{\mu'}$  を考えると、この内部に含まれる  $V_i$  と、 $\nu'Z_i > 0$  となる  $Z_i$  とは互いに 1 対 1 に対応するので、

$$W_n(\nu) \equiv (1/n) \sum_{i=1}^n I[\nu'X_i > 0]$$

$$\text{と置くと、} \quad W_n(\nu_n) \leq (1/n)T_n$$

であるという事が解る。  $\Sigma^{-1}\mu$  に直交する vector で上半平面にあるものを  $\tau$  とするとき、領域  $\{x \mid \arg(\mu) \leq \arg(x) \leq \arg(\tau) \text{ or } \arg(-\mu) \leq \arg(x) \leq \arg(-\tau)\}$  の確率は elliptical 性から  $1/2$  に等しいので、定義より  $\nu_n$  は  $\Sigma^{-1}\mu$  の一致推定量になっていることも解る。 また

$$(1/n)T_n \leq (1/n) \sup_{0 \leq t \leq 2} T_n(t)$$

$$= \sup_{\nu \neq 0} W_n(\nu)$$

である。  $W_n(\nu)$  は、  $\nu$  の argument の関数としてながめるとき定数関数  $P(\nu'X_i > 0 \mid \theta = \mu) = \Psi(\nu'\mu / (\nu'\Sigma\nu)^{1/2})$  に弱収束する。このことより

$$\begin{aligned} \Psi(\Delta) &\leq \lim_{n \rightarrow \infty} (1/n) T_n \\ &\leq \sup_{\nu \neq 0} \Psi(\nu'\mu / (\nu'\Sigma\nu)^{1/2}) \\ &= \Psi(\Delta) \end{aligned}$$

を得る。ただし  $\Delta = (\mu'\Sigma^{-1}\mu)^{1/2}$  である。ゆえに

$$\begin{aligned} b(\mu) &= \lim_{n \rightarrow \infty} (1/\sqrt{n}) S_n \\ &= \lim_{n \rightarrow \infty} (2/n) (T_n - n/2) \\ &= 2\Psi(\Delta) - 1 \end{aligned}$$

となる。

以上により  $S_n$  の Bahadur slope は  $(2\Psi(\Delta) - 1)^2$  となることが解る。これは結局、制約条件がない場合の Bahadur slope と同じである。よって、この量によっては、制約条件がある場合と、ない場合との差はみつけれない。また Hotelling の  $T^2$  検定の slope は、分散が存在して  $\Sigma$  に等しいとき、 $\Delta^2$  になるので、我々の検定の  $T^2$  検定に対する Bahadur efficiency は

$$(2\Psi(\Delta) - 1)^2 / \Delta^2$$

で得られる。これは1次元で  $\Delta = \mu / \sigma$  と置いたときの  $t$  検定に対する sign 検定の Bhadur efficiency に等しい。 $\Psi = \Phi$  で  $\mu \rightarrow \infty$  としたとき、この値がその時の Pitman efficiency  $2/\pi$  になるという事実も良く知られている。