

# 15 等間隔抽出法について

青山 博次郎

大きさ  $N$  の母集団から  $n$  個のサンプルを抽出するとき等間隔抽出法を利用することが実際によく用いられている。これに関して実用上の注意をのべることにしてよう。

## §1 $N$ が $n$ より大きいときの誤差について

通常  $N = kn$  の場合のみが論じられている。そうして

$$N = kn - r, \quad 0 < r < n$$


なるとき  $n > 50$  なるとき

$$\text{近似的に} \quad E(\bar{x}) = \mu$$

但し  $\bar{x}$  は母平均  $\mu$

が成立することによって議論が進められる。

この理由を容易に分るために計算してみよう。



$1 \leq i \leq n$  として、 $i$  がランダム・スタートとしてえらばれるとき、サンプルの平均は

$$\bar{x}_i = \frac{x_i + x_{i+n} + \dots + x_{i+(n-1)k}}{n} \quad (1)$$

但し  $n = k, \quad i \leq k - r$

$n = k - 1, \quad i > k - r$

とする。

このとき

$$E(\bar{x}_i) = \frac{1}{n} \sum_{j=1}^{k-r} (x_j + x_{j+k} + \dots + x_{j+(n-1)k}) + \frac{1}{(n-1)k} \sum_{j=1}^r (x_{k-r+j})$$

$$+ X_{(n-r+j)r} + \dots + X_{(n-r+j+(n-2)r)} \\ = (1 - \frac{r}{n}) \bar{X}_1 + \frac{r}{n} \bar{X}_2 \quad (2)$$

ここで  $\bar{X}_1$  は  $n(n-r)$  個のもの（第1群と名付ける）の平均、 $\bar{X}_2$  は  $(n-1)r$  個の半端もの（第2群と名付ける）の平均とする。

一方母平均は

$$\bar{X} = \frac{\bar{X}_1 n(n-r) + \bar{X}_2 r(n-1)}{n(n-r) + r(n-1)} = \bar{X}_1 \frac{n-r}{n-1} + \bar{X}_2 \frac{r}{n-1} \quad (3)$$

それ故  $n > 50$  程度ならば

$$E(\bar{X}_1) \approx \bar{X} \quad (4)$$

となる。

$\bar{X}_2$  の分散については

$$V(\bar{X}_2) = (1 - \frac{r}{n})^2 (\bar{X}_1^2 + \sigma_1^2) + \frac{r}{n} (\bar{X}_2^2 + \sigma_2^2) - \frac{1}{n} \sum_{i=1}^{n-r} \sigma_i^{*2} - \left\{ \bar{X}_1 (1 - \frac{r}{n}) + \bar{X}_2 \frac{r}{n} \right\}^2 \quad (5)$$

但し  $\sigma_1^2, \sigma_2^2$  はそれぞれ第1, 2群の母分散とし、 $\sigma_i^{*2}$  は第1群の母分散である。

従って Mean Square Error は全体の母分散を  $\sigma^2$  とすると

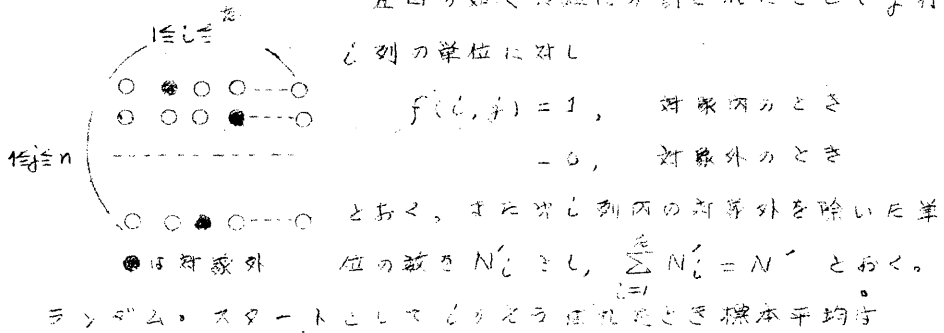
$$M.S.E. (\bar{X}_2) \approx \sigma^2 - \frac{1}{n} \sum_{i=1}^{n-r} \sigma_i^{*2} \quad (6)$$

## §2 $N = nr$ の場合で対象外のサンプルを含む場合

我々が通常サンプルを抽出するとき等として抽出を用いることが多い。例えば選挙人名簿がそれであるが、時々刻々変化しないうちでも、調査時から現在までに名簿には訂正が加えられているのが普通である。このとき正確に我々が算出されるべき比率は通常の場合は大差で抽出するに代り、抽出しやすい5とか10の倍率を用いて等間隔抽出を行い、もし対象外（転出、死亡等）の

の者が当ればとれを写して、行く方法がどの様になっている、この方法、bias をもっていることは明らかであるが、近似的に等間隔抽出法として取扱っている、これについて考察する。

左図の如くを組に分割されたとして  $f$  行



$$\bar{x}'_i = \frac{x_1 f(i, 1) + x_2 f(i, 2) + \dots + x_{(i, n)} f(i, n)}{\sum_{j=1}^n f(i, j)} \quad (7)$$

このとき

$$E(\bar{x}'_i) = \frac{1}{N'} \sum_{i=1}^k \bar{x}'_i \quad (8)$$

と置くことは容易に分る。

母平均は

$$\bar{x} = \frac{N'_1 \bar{x}'_1 + N'_2 \bar{x}'_2 + \dots + N'_k \bar{x}'_k}{N'} \quad (9)$$

であるから、一般には

$$E(\bar{x}'_i) \neq \bar{x}$$

となり combined とは異なる。

このとき

$$\begin{aligned} V(\bar{x}') &= E\left(\bar{x}'_i - \frac{1}{N'} \sum_{j=1}^k \bar{x}'_j\right)^2 \\ &= \frac{1}{N'} \sum_{i=1}^k (\bar{x}'_i - \bar{x})^2 \left(\bar{x}'_i - \frac{1}{N'} \sum_{j=1}^k \bar{x}'_j\right)^2 \end{aligned} \quad (10)$$

従って

$$M.S.E.(\bar{x}'_i) = \frac{1}{R} \sum_{l=1}^{N'_i} (\bar{x}'_{il} - \bar{x}')^2 \quad (11)$$

さて  $\bar{x}'_i$  の bias の order を求めるために次のように考え  
みる。即ち  $N$  個の単位が成組の  $N'_1, N'_2, \dots, N'_k$  に random  
に分割されると考えると

$$\begin{aligned} \frac{1}{R} \sum_{l=1}^{N'_i} \bar{x}'_{il} &= \frac{1}{R} \left\{ \frac{1}{N'_1} (X_{11} + \dots + X_{1N'_1}) + \frac{1}{N'_2} (X_{21} + \dots + X_{2N'_2}) \right. \\ &\quad \left. + \dots + \frac{1}{N'_k} (X_{k1} + \dots + X_{kN'_k}) \right\} \end{aligned} \quad (12)$$

であるから、この分母もまた確率変数である。

そこで各項毎に期望値をとると

$$E\left\{ \frac{1}{N'_i} (X_{i1} + \dots + X_{iN'_i}) \right\} = \frac{E(X_{i1} + \dots + X_{iN'_i})}{E(N'_i)} + E(R_i) - \bar{x}' + E(R_i) \quad (13)$$

ここに  $R_i$  は誤差項を示す。

従って

$$E\left( \frac{1}{R} \sum_{l=1}^{N'_i} \bar{x}'_{il} \right) = \bar{x}' + E\left( \frac{1}{R} \sum_{l=1}^{N'_i} R_{il} \right) \quad (14)$$

次節でのべる如く

$$E(N'_i) = \frac{N'}{k} = \bar{N}' \quad (15)$$

となるから

$$E(R_i) = \frac{E(X_{i1} + \dots + X_{iN'_i}) \bar{V}(N'_i)}{\{E(N'_i)\}^2} = \frac{R^2 \bar{x}'}{V^2} \tau^2 = \frac{\bar{x}'}{V^2} \tau^2$$

$$\text{但し } \bar{V}(N'_i) = \tau^2 \quad (16)$$

$$\therefore E\left( \frac{1}{R} \sum_{l=1}^{N'_i} R_{il} \right) = \frac{\bar{x}'}{N'^2} \tau^2 \quad (17)$$

故に以上の如き仮定の下において  $E(\bar{x}'_i)$  の平均は

$$\bar{E}(z'_i) = \bar{X}' + \frac{\bar{X}}{N'^2} \tau^2 \quad (18)$$

また

$$\begin{aligned} \nabla \left( \frac{1}{N'_i} (X_{i1} + \dots + X_{iN'_i}) \right) &= \frac{\nabla(X_{i1} + \dots + X_{iN'_i})}{\{E(N'_i)\}^2} + \frac{\bar{X}'^2 \tau^2}{\{E(N'_i)\}^2} \\ &= 2\beta_i \tau \bar{X}' \frac{\sqrt{\nabla(X_{i1} + \dots + X_{iN'_i})}}{\{E(N'_i)\}^2} \end{aligned}$$

ここで  $\beta_i$  は  $N'_i$  と  $X_{ij} = \sum_{j=1}^{N'_i} X_{ij}$  の相関係数とする。

然るに右側の計算の後、 $\sigma^2$  を母分散として

$$\begin{aligned} \nabla(X_{i1} + \dots + X_{iN'_i}) &= E \left( \sum_{j=1}^{N'_i} X_{ij} - \bar{N}' \bar{X}' \right)^2 \\ &= \frac{N'^2 (k_i - 1) - \tau^2}{N' - 1} \cdot \sigma^2 + \tau^2 \bar{X}'^2 \end{aligned}$$

となるから

$$\begin{aligned} \nabla \left( \frac{1}{N'_i} \sum_{j=1}^{N'_i} X_{ij} \right) &= \frac{\bar{N}'^2 (k_i - 1) - \tau^2}{N' - 1} \frac{\sigma^2}{N'^2} + 2\tau^2 \frac{\bar{X}'^2}{N'^2} - 2\beta_i \tau \frac{\bar{X}'}{N'^2} \\ &\quad \sqrt{\frac{\bar{N}'^2 (k_i - 1) - \tau^2 \sigma^2}{N' - 1} + \tau^2 \bar{X}'^2} \quad (19) \end{aligned}$$

従って  $\nabla(z'_i)$  の平均は

$$\begin{aligned} \bar{\nabla}(z'_i) &= E(\nabla(z'_i)) = \frac{k_i - 1}{N'} \left( \frac{\bar{N}'^2 (k_i - 1) - \tau^2}{N' - 1} \frac{\sigma^2}{N'^2} + 2\tau^2 \frac{\bar{X}'^2}{N'^2} \right) \\ &\quad - \frac{2\tau(k_i - 1)\bar{X}'}{N'^2} \sqrt{\frac{\bar{N}'^2 (k_i - 1) - \tau^2}{N' - 1} \sigma^2 + \tau^2 \bar{X}'^2} \cdot \sum_{i=1}^k S_i \\ &\quad + (\bar{X}'_i, \bar{X}'_j \text{ の相関係数を含む項}) \quad (20) \end{aligned}$$

近似的には  $\tau \approx 0$ ,  $\beta_i \approx 0$  等とおけるから

$$\overline{V}(\overline{X}') \doteq \frac{(k-1)^2}{k} \frac{\sigma^2}{N-1} \doteq \frac{\sigma^2}{N'} \quad (20)$$

以上の所論を簡単な例によつて示してみよう。次の例は昭和26年度の東京都知事選挙に際して参照した豊高区池袋4丁目の基本選挙人名簿からとつたものである。実際上の端数は切捨てで、丁度  $N = nk$  ( $n$  はサンプル数,  $k$  は抽出間隔である) とすると

$$N = 2580, N' = 2476, k = 60, n = 43, \overline{N}' \doteq 41.3$$

このとき対称外の者の数は次のように現われた。

1, 4, 4, 2, 4, 6, 9, 11, 8, 0, 1, 2, 1, 1, 0,  
 2, 0, 1, 1, 2, 2, 1, 1, 0, 1, 3, 1, 1, 1, 2,  
 0, 1, 0, 0, 0, 4, 0, 1, 0, 2, 1, 0, 0, 2, 0,  
 1, 2, 1, 0, 4, 1, 1, 1, 2, 1, 2, 0, 3, 0, 1,

従つてこの数列から  $\overline{V}(N_i') = \tau^2$  の推定値として 4.773 が得られる。これを (18) に代入すると  $\overline{E}(\overline{X}')$  の偏りは  $\overline{X}'$  の

$$\frac{\tau^2}{\overline{N}'^2} \times 100\% = 0.284\%$$

程度であることが分る。

### §3 自然数の分割数について

前節で対称外の者が含まれた  $N$  人の者が  $k$  組に分けられる方法が等確率で起ると仮定して  $\overline{E}(\overline{X}')$  を求めた。その時に用いた性質を以下証明してみよう。記号を簡単にするためしばらくダッシュを除いて書く。

今  $N$  個のものを  $k$  組 ( $N \geq k$  とする) に分ける方法は幾通りあるかという、0個の組も許せば

$$P_k(N+kr)$$

個である。ここで  $P_k(m)$  は自然数  $m$  を丁度  $k$  組の自然数に分ける方法の数を示し

$$\sum_{m, k=0}^{\infty} P_k(m) x^m z^k = \frac{1}{(1-xz)(1-x^2z)\dots} \quad (21)$$

$$P_k(m) = \sum_{l=1}^k P_l(m-kr) \quad (22)$$

なる性質があることが知られている。(注)

例えば  $N=5, k=3$  ならば  $P_3(8)=5$  となり

$$\begin{aligned} N &= 0+0+5 \\ &= 0+1+4 \\ &= 0+2+3 \\ &= 1+1+3 \\ &= 1+2+2 \end{aligned}$$

は互ら通りの分割法がある。しかも我々は各道の中の 1つをサンプルとして抽出したと考えられるので、結局

$$N = N_1 + N_2 + \dots + N_k$$

となった時の  $E(N_i), \nabla(N_i)$  は  $k P_k(N+kr)$  個の  $N_i$  の平均, 分散を求めればよいことになるのである。

ここで 0 の数を  $F_{N,k}(0)$ , 1 の数を  $F_{N,k}(1)$ , ……として表わせば

$$\sum_{x=0}^N F_{N,k}(x) = k P_k(N+kr) \quad (23)$$

(注) 伏見康治：確率論及統計論，河出書房，昭和17年

また容易に分る如く

$$F_{N, k}(0) = \binom{k-1}{0} P_1(N) + \binom{k-2}{0} P_2(N) + \dots + P_{k-1}(N) \quad (24)$$

数学的帰納法により

$$\begin{aligned} F_{N, k}(x) &= P_1(N-x) + P_2(N-x) + \dots + P_{k-1}(N-x) \\ &\quad + P_1(N-2x) + P_2(N-2x) + \dots + P_{k-2}(N-2x) \\ &\quad + \dots \\ &\quad + P_1(N-(k-1)x) + \delta_{N=kx} \\ &= P_{k-1}(N-k-(x+1)) + P_{k-2}(N+k-2(x+1)) + \dots \\ &\quad + P_1(N+k-(k-1)(x+1)) + \delta_{N=kx} \end{aligned} \quad (26)$$

なることが証明できる。ここで勿論  $m < k$  のとき

$$P_k(m) = 0 \quad \text{とし,}$$

$$\left. \begin{aligned} \delta_{N=kx} &= 1, & N &= kx \\ &= 0, & N &\neq kx \end{aligned} \right\}$$

とおく。

これらの関係式から

$$\sum_{x=0}^N x F_{N, k}(x) = N P_k(N+k) \quad (27)$$

なることが証明できる。それは  $(N, k+1)$  及び  $(N+1, k)$  について (27) が成立つとき

$$\sum_{x=0}^{N+1} x F_{N+1, k+1}(x) = \sum_{x=0}^{N+1} x (F_{N+1, k}(x) + F_{N-k, k+1}(x-1))$$



$$\begin{aligned}
&= (N+1)P_{r_1(N+r_1+1)} + (N+1)P_{r_1+1}(N+1) \\
&= (N+1)P_{r_1+1}(N+r_1+2)
\end{aligned}$$

となることより、二重帰納法を用いて証明できる。

故に分割数の組成数たる  $r_1 P_{r_1}(N+r_1)$  個のものの平均は

$$\frac{\sum_{\lambda} x F_{N, r_1}(\lambda)}{r_1 P_{r_1}(N+r_1)} = \frac{N}{r_1} \quad (28)$$

となる。

分散については一般式が得られないので評価式を用いることにする。このため以下詳細に  $N'$  の記号を用いる。

先ず我々の問題の性質上、 $N'$  個のものを  $r_1$  組に分けるのであるが、一組の個数は  $n$  (但し  $N = n r_1$ ) より大きくはなり得ない。従って (28) 式は変更を要する訳であるが、このとき  $n+1$  個以上のものを含む場合が  $A$  通り出来るとすると、容易に分る如く

$$\text{平均} = \frac{N' P_{r_1}(N'+r_1) - N'A}{r_1 P_{r_1}(N'+r_1) - r_1 A} = \frac{N'}{r_1} \quad (28)$$

となって平均は変りない。

分散については上述の  $A$  通りを除いたものの  $F$  を  $F^*$  で置きかえ

$$\sum_{\lambda=0}^n x^2 F_{N, r_1}^*(\lambda) < n^2 \sum_{\lambda=0}^n F_{N, r_1}^*(\lambda)$$

$$\therefore \tau^2 = \frac{\sum x^2 F_{N, r_1}^*(\lambda)}{\sum F_{N, r_1}^*(\lambda)} - \frac{N'^2}{r_1^2} < n^2 - \frac{N'^2}{r_1^2} = \frac{N'^2}{r_1^2} \left( \frac{N^2}{N'^2} - 1 \right) \quad (29)$$

故に前節の  $\bar{E}(\bar{x}'_i)$  の bias の  $\bar{X}'$  に対する相対割合は

$$\frac{\tau^2}{N'^2} < \frac{N^2}{N'^2} - 1 \quad (30)$$

となる。

池袋4丁目の例にあてはめると

$$N' = 2476 = 0.96N$$

であるから

$$\frac{\tau^2}{N'^2} < 0.085$$

#### §4. サンプル数 $n$ を確保する場合

§2で許容外を除いたまま平均を確定した。しかし問題によってはサンプル数  $n$  を確保しなければならぬ場合がある。このとき飲けたものを残りのものから random に充てる場合を考えよう。即ち

第  $i$  列が充らば残るとき、残りの  $N' - N'_i$  個のものからサンプルを  $n - N'_i$  個充てるのである。このときの推定平均を  $\bar{x}''_i$  とすると

$$\begin{aligned} \bar{x}''_i &= \frac{1}{n} (x_{i1}f(i,1) + x_{i2}f(i,2) + \dots + x_{i+(n-1)}f(i,n)) \\ &+ \frac{1}{n} (x_{j_1} + x_{j_2} + \dots + x_{j, n-N'_i}) \end{aligned} \quad (31)$$

このとき

$$\begin{aligned} E(\bar{x}_i'') &= \frac{1}{nN} \left( \sum_{i=1}^k N_i' \bar{X}_i' + \sum_{i=1}^k \frac{n-N_i'}{N'-N_i'} \sum_{j \neq i} N_j' \bar{X}_j' \right) \\ &= \frac{1}{nN} \left\{ N' \bar{X}' + \sum_{i=1}^k \frac{n-N_i'}{N'-N_i'} (N' \bar{X}' - N_i' \bar{X}_i') \right\} \end{aligned} \quad (32)$$

ここで  $\sum_{j \neq i}$  は  $i$  を除いて加えることを示す。

当然ながら  $\bar{X} = \bar{X}_i'$  ならば

$$E(\bar{x}_i'') = \bar{X}' \quad (33)$$

また  $N_i' = N'$  であっても (33) は成立する。

一般には (32) は  $\bar{X}'$  に等しくないから  $\bar{x}_i''$  は bias を持っている。その値を  $B_2$  とし、§2 で得た  $\bar{x}_i'$  の bias を  $B_1$  とする。

このとき

$$B_1 = \frac{1}{n} \sum_{i=1}^k \bar{X}_i' - \bar{X}' = \sum_{i=1}^k \bar{X}_i' \left( \frac{1}{n} - \frac{N_i'}{N'} \right)$$

$$B_2 = \frac{N'}{N} \bar{X}' \left( 1 + \sum_{i=1}^k \frac{n-N_i'}{N'-N_i'} \right) - \frac{1}{N} \sum_{i=1}^k \frac{n-N_i'}{N'-N_i'} N_i' \bar{X}_i' - \bar{X}'$$

もし  $N_i' \equiv \frac{N'}{n}$  とおけるならば

$$B_2 \equiv \frac{N-N'}{N(n-1)} \sum_{i=1}^k \bar{X}_i' \left( \frac{N_i'}{N'} - \frac{1}{n} \right)$$

となるから  $|B_2| \leq |B_1|$

となる

簡単な例をあげてみるとその様子が分る。

1	X	1	6	4
8	2	X	8	1
0	5	2	9	1
9	4	5	X	7
6	0	9	4	1

(但し X は対象外)

$$N = 25, \quad N' = 22, \quad n = 5, \quad k = 5$$

$$\bar{X}' = 4.2272$$

$$E(\bar{X}'_i) = 4.27,$$

$$E(\bar{X}''_i) = 4.2177,$$

$$|B_1| = 0.0428$$

$$|B_2| = 0.0095$$

$\bar{X}''_i$  の分散は  $N'_i \bar{X}'_i$ ,  $(n - N'_i) \bar{X}''_{i-1}$  の相関係数を  $\rho$  とおくとき

$$\begin{aligned} V(\bar{X}''_i) &= \frac{1}{nN} \sum_i N_i^2 \bar{X}'_i{}^2 - \frac{N'^2}{N^2} \bar{X}'^2 + \frac{1}{n^2} \left\{ \frac{1}{k} \sum_i \left( \frac{n - N'_i}{N - N'_i} (N\bar{X}' - N'_i \bar{X}'_i) \right)^2 \right. \\ &\quad \left. - \left( \frac{1}{k} \sum_i \frac{n - N'_i}{N - N'_i} (N\bar{X}' - N'_i \bar{X}'_i) \right)^2 \right\} + \frac{N' - n}{nN} \sum_i \frac{n - N'_i}{N - N'_i} \sigma_i^2 \\ &\quad + 2\rho \sqrt{\frac{1}{nN} \sum_i N_i^2 \bar{X}'_i{}^2 - \frac{N'^2}{N^2} \bar{X}'^2} \sqrt{\frac{N' - n}{nN} \sum_i \frac{n - N'_i}{N - N'_i} \sigma_i^2} \\ &= \frac{1}{n^2} \left\{ V(N'_i \bar{X}'_i) + V\left( \frac{n - N'_i}{N - N'_i} (N\bar{X}' - N'_i \bar{X}'_i) \right) + \frac{N' - n}{k} \sum_i \frac{n - N'_i}{N - N'_i} \sigma_i^2 \right. \\ &\quad \left. + 2\rho \sqrt{V(N'_i \bar{X}'_i)} \sqrt{\frac{N' - n}{k} \sum_i \frac{n - N'_i}{N - N'_i} \sigma_i^2} \right\} \quad (34) \end{aligned}$$

となる

但し  $\sigma_i^2$  は  $X_i$  組を除いたものの分散を示す。

このときも  $\frac{N'_i}{N} \doteq \frac{1}{k}$  とおければ

$$\begin{aligned} V(\bar{x}_i'') &= \frac{N^2(k-1)^2 - (N-N')^2}{N^2(k-1)^2} V(\bar{x}_i') \\ &+ \frac{(N-N')(N'-n)}{nN N'(k-1)} \sum \bar{\sigma}_i^2 + (\rho \text{ を含む項}) \end{aligned}$$

となり、3項が1項に比べて無視できる場合は

$$V(\bar{x}_i'') < V(\bar{x}_i')$$

となるから M. S. E. は  $\bar{x}_i''$  の方が小さくなることが分る。

前の数値例では

$$V(\bar{x}_i') = 2.1806, \quad V(\bar{x}_i'') = 1.6797$$

となり、

$$\text{M. S. E.}(\bar{x}_i') \doteq 2.1824$$

$$\text{M. S. E.}(\bar{x}_i'') \doteq 1.6798$$

となって  $\bar{x}_i''$  の方が良い推定値を与える。