

### ③ Sampling System について

水野

#### §0 前書

Sampling Estimation をする時の考へ方を分析してみると次の様になると思はれる。

我々が調べたい対象の集りがある。之は我々が *merkmal* と呼んでゐるものを *Element* とする集合である。之を *Universe* と云ふ事にする。我々が知りたいのは此の *Universe* の *Element* に依つて決定されるある量  $\theta$  である。之を *Universe Parameter* と呼ぼう。

我々は此地で *Universe* の任意の *Element* に夫々等しい *Probability* を與へる。此の *Probability Field* を  $\Omega$  で表はさう。

註 始めの  $\Omega$  を *Population* と呼んだが、*Population* なる語の不明確性を失くす爲關係諸代との *discussion* の結果此の名前を使はない事にした。

$\Omega$  で *Expectation* が量としては  $\theta$  に等しくなる様な函数<sup>f</sup>に着目する。

我々は  $f$  の実現値の大きさを以て、 $\theta$  の大きさに見做すのである。

註 *biand* と *estimate* には以下の論を簡単にする為、ふれ合いが全く平行的に行はれる

之が *Sampling* に依つて、或る *Universe Parameter*  $\theta$  を推定する時の構造である。

此処で、我々の見做しが有効である様にと幾つかの提案がなされてきた。其は種々の *Estimate* の提唱とか *Stratification* の使用とかの形をとつたが、本質的なものとしては  $f$  の変動の範囲が人間の尺度に於ける  $\theta$  を除いて、充分  $\theta$  に近接してゐるといふ事、換言すれば *Unbiased* で *Variance* が小さいといふ事が *negligible* な *Rias* を持ち、その *Mean Square Error* が小さいと云ふ事であつた。そして此処に於て *Optimum<sup>m</sup>* な *Estimate* とか、*Optimum* な *Allocation* といふ事が問題とされてきた。

斯う考へてくると問題が生じてくる。推定を行ふ爲に確率論的構造を持つた  $\Omega$  を想定して考へるのが一番穩当な方法であつたといふ事を認めるとしても、何故 *Efficiency* を考へる時に、此の特殊な  $\Omega$  で考察する必要があるらうかと。

*Probability field* を作る時、その各 *Element* に対応する *Probability* を等しくする必要はないではないか。考へられる種

種の Probability field で Efficiency を考へた方がより合理的であらう。斯くして Sampling System の話は始る。

§ 1 Probability field  $\Omega_p$  の構成

Universe の size を  $N$  とする。その Element を  $X_1, \dots, X_N$  とする。簡単の爲にその量も同一の記号で表はす事にする。

註  $X$  は一般に Vector であつてよい。

我々が知りたいのは Universe parameter  $\theta$  だとする。

(1)  $\theta \equiv F(X_1, \dots, X_N)$

$X_{(i)}$ ;  $i = 1, \dots, n$  を  $X_1, \dots, X_N$  の何れか一つの値をとる様な変量をとる。

今  $(i_1, \dots, i_n)$  を  $1, \dots, N$  からとられた size  $n$  の任意の組合せとする。

註  $(i_1, \dots, i_n)$  を任意の size  $n$  なる順列とする事も可能である。此の場合以下の議論も全く平行的に行へる。

今任意の  $(X_{i_1}, \dots, X_{i_n})$  なる組に対して定義された負ならざる函数  $P(X_{(1)}, \dots, X_{(n)})$  を考へる。そして  $(X_{i_1}, \dots, X_{i_n})$  なる Element の組に対して  $P(X_{i_1}, \dots, X_{i_n})$  に比例する Probability

を考へる。即ち  $\frac{P(X_{i_1}, \dots, X_{i_n})}{\sum P(X_{i_1}, \dots, X_{i_n})}$  なる Probability だ

$(X_{i_1}, \dots, X_{i_n})$  なる組が抽出される様な Probability field を構成する。此處に  $\sum$  は總ての  $(i_1, \dots, i_n)$  に及ぶものとする。

此の Probability field を  $P$  に Proportionate な Probability

field を呼び  $\Omega_p$  で表はさる。之は Equally likely な Probability field といふ時、即ち  $P$  とし  $\Omega_p$  を  $\Omega$  で表はす。

field と呼ばれるものである。

## §. 2 Estimate $f_p$ の構成

今  $\Omega$  で 或函数  $f(X_{(1)}, \dots, X_{(n)})$  が  $\theta$  の unbiased estimate  $f$  とする。即ち

$$(2) \quad E_{\Omega} [f(X_{(1)}, \dots, X_{(n)})] = \sum f(X_{i_1}, \dots, X_{i_n}) \frac{1}{\binom{N}{n}} \\ = \theta$$

こゝに  $E_{\Omega}$  は  $\Omega$  での Expectation を表はす。

此處で組  $X_{i_1}, \dots, X_{i_n}$  に対して

$$(3) \quad f_p(X_{i_1}, \dots, X_{i_n}) = \frac{f(X_{i_1}, \dots, X_{i_n})}{\frac{P(X_{i_1}, \dots, X_{i_n})}{\sum P(X_{i_1}, \dots, X_{i_n})}} = \frac{1}{\binom{N}{n}}$$

で定義される函数  $f_p(X_{(1)}, \dots, X_{(n)})$  を考へる。

然らば明らかに  $f_p(X_{(1)}, \dots, X_{(n)})$  は  $\Omega_p$  で  $\theta$  の unbiased estimate とする。

$$(4) \quad E_{\Omega_p} [f_p(X_{(1)}, \dots, X_{(n)})] \\ = \sum \frac{f(X_{i_1}, \dots, X_{i_n})}{\frac{P(X_{i_1}, \dots, X_{i_n})}{\sum P(X_{i_1}, \dots, X_{i_n})}} \cdot \frac{1}{\binom{N}{n}} \cdot \frac{P(X_{i_1}, \dots, X_{i_n})}{\sum P(X_{i_1}, \dots, X_{i_n})} \\ = \sum f(X_{i_1}, \dots, X_{i_n}) \cdot \frac{1}{\binom{N}{n}} \\ = \theta$$

## §. 3. Sampling System

或る数  $f$  が  $\theta$  の Estimate であるのは Probability field  $\Omega$  が  $f$  へられるからであつて  $f$  は  $\Omega$  に relative なものである。

依つて、今  $f$  が  $\Omega$  で  $\theta$  の estimate とされる時は、 $\Omega, f$  の組を以て  $\theta$  に対する Sampling System と稱し  $(\Omega, f)$  で表はす。

$$(5) E_{\Omega}(f) = \theta$$

が成立する時、Sampling System  $(\Omega, f)$  は unbiased なりといふ。

又  $\Omega$  に於ける  $f$  の variance を以て Sampling System  $(\Omega, f)$  の Variance と稱し  $V_{\Omega}(f)$  で表はす。

$$(6) V_{\Omega}(f) = E_{\Omega} [f - E_{\Omega}(f)]^2$$

然らば我々としては、Unbiased で minimum な Variance を持つ Sampling System を求めるのが当りであらう。

前に考察した  $\Omega_p, f_p$  を以て Sampling System  $(\Omega_p, f_p)$  を考へれば、之は  $\theta$  の unbiased な Sampling System となり。

Variance は次式で与へられる。

$$(7) V_{\Omega_p}(f_p) = E_{\Omega_p}(f_p^2) - \{E_{\Omega_p}(f_p)\}^2$$

$$= \sum \frac{\{f(X_{i1}, \dots, X_{in})\}^2}{\left\{ \frac{P(X_{i1}, \dots, X_{in})}{\sum P(X_{i1}, \dots, X_{in})} \right\}^2} \cdot \frac{1}{\binom{N}{n}} \cdot \frac{P(X_{i1}, \dots, X_{in})}{\sum P(X_{i1}, \dots, X_{in})} - \theta^2$$

$$= \sum \frac{\{f(X_{i1}, \dots, X_{in})\}^2}{P(X_{i1}, \dots, X_{in})} \cdot \frac{1}{\binom{N}{n}} \cdot \sum \frac{P(X_{i1}, \dots, X_{in})}{\binom{N}{n}} - \theta^2$$

$$= E_{\Omega} \left[ \frac{f^2(X_{(1)}, \dots, X_{(n)})}{P(X_{11}, \dots, X_{1n})} \right] \cdot E_{\Omega} [P(X_{(1)}, \dots, X_{(n)})] - \theta^2$$

#### §. 4. Efficiency

Sampling System  $(\Omega_p, f_p)$  の Efficiency  $\alpha(\Omega_p, f_p)$  を次の量で測る。

$$(8) \quad \alpha(\Omega_p, f_p) = \frac{V_{\Omega}(f)}{V_{\Omega_p}(f_p)}$$

$$(9) \quad \alpha(\Omega_p, f_p) > \alpha(\Omega_{p'}, f_{p'})$$

なる時  $(\Omega_p, f_p)$  は  $(\Omega_{p'}, f_{p'})$  より efficient であるといふ。

$\theta$  の値の Sampling System  $(\Omega_p, f_p)$  をきめる際には出来るだけ efficient な Sampling System をとればよい。

明らかに Equally likely な Sampling System の efficiency は 1 であり、 $(\Omega_f, f_f)$  の Efficiency は  $\infty$  である。

此の事は以下の論に示唆をよめる。

我々の採用し得る  $P$  が任意の函数であるなら問題はないのだが、我々の知識は、即我々の利用し得る函数族  $\{P\}$  は限定されたものであるから、我々は此の函数族の中で最も Efficiency の高いものを採用するより仕方がない。

よへられた函数族  $\{P\}$  に対して  $\alpha(\Omega_p, f_p)$  が maximum である函数  $\hat{P}$  の決定する Sampling System を optimum といふ。

#### §. 5. $\alpha(\Omega_p, f_p)$ の近似式

次の式が成立する。

$$(9) \quad E\left(\frac{Y^2}{X}\right) = E\left(\frac{Y^2}{X^2}\right) \cdot E(X) + \varphi_1(X, Y)$$

∴ > 12

$$(10) \quad \varphi_1(X, Y) = \frac{E\left(\frac{E(X)-X}{X} \cdot \frac{Y^2}{X^2}\right)}{E\left(\frac{1}{X}\right)} - E(X)E\left(\frac{Y^2}{X^2}\right) = \frac{E\left(\frac{E(X)-X}{X}\right)}{1+E\left(\frac{E(X)-X}{X}\right)}$$

又

$$(11) \quad E\left(\frac{Y}{X}\right) = \frac{E(Y)}{E(X)} + \varphi_2(X, Y)$$

∴ > 12

$$(12) \quad \varphi_2(X, Y) = \frac{E\left(\frac{E(X)-X}{X} \cdot Y\right)}{E(X)}$$

又

$$(13) \quad V\left(\frac{Y}{X}\right) = \frac{E^2(Y)}{E^2(X)} \left\{ C_x^2 - 2\rho C_x C_Y + C_Y^2 \right\} + \varphi_3(X, Y)$$

∴ > 12

$$(14) \quad \varphi_3(X, Y) = \frac{1}{E^2(X)} \left\{ \frac{E(Y)}{E(X)} - E\left(\frac{Y}{X}\right) \right\}^2 + 2\rho C_x C_Y \frac{E(Y)}{E(X)} \left\{ \frac{E(Y)}{E(X)} - E\left(\frac{Y}{X}\right) \right\} - C_x^2 \left\{ \frac{E^2(Y)}{E^2(X)} - E^2\left(\frac{Y}{X}\right) \right\} - \frac{1}{E(X)} E \left\{ \frac{\{X^2 - E^2(X)\} \{Y^2 - X \frac{E(Y)}{E(X)}\}^2}{X^2} \right\}$$

$P_1$  は Correlation Coefficient を  $C$  は Coefficient of variation を表す。

依つて

$$(15) \quad \alpha(\Omega_p, f_p) = \frac{C_f^2}{C_f^2(1-p) + (C_p - pC_f)^2 + 4\varphi'(f, p)}$$

$$= \frac{1}{(1-p)^2 + \left(\frac{C_p}{C_f} - p\right)^2 + \varphi(f, p)}$$

となる。こゝに  $p$  は  $f, P$  の Correlation Coefficient を  $\varphi(f, P)$  は  $\varphi_1, \varphi_2, \varphi_3$  を含む函数である。

### §. 6. Optimum Sampling System の近似的決定

前§の  $\varphi$  が第一項に対して省略できるなら、 $\alpha(\Omega_p, f_p)$  は近似的に

$$(16) \quad \frac{1}{(1-p)^2 + \left(\frac{C_p}{C_f} - p\right)^2}$$

で与えられる。

今我々が一つの函数  $P$  の知識を持つてるとするなら次の様にする事が可能である。

$\lambda$  を常教として

$$(17) \quad P^* = P + \lambda E_{\Omega}(P)$$

とおく

$\lambda$  が与えられるなら 当然  $P^*$  の知識は完全である。

然る時

$$(18) \quad E_{\Omega}(P^*) = (1 + \lambda) E_{\Omega}(P)$$

$$(19) \quad V_{\Omega}(P^*) = V_{\Omega}(P)$$

$$(20) \quad f_{f,P} = f_{f \cdot P}$$

であるから

$$(21) \quad \alpha(\Omega_{p^*}, f_{p^*}) = \frac{1}{(1-\rho^2) + \left(\frac{C_p}{C_f} \frac{1}{1+\lambda} - \rho\right)} + \varphi$$

となる。

依って

$$(22) \quad \lambda = \frac{1}{\rho} \cdot \frac{C_p}{C_f} - 1$$

なる如く  $\lambda$  を決定すれば

$$(23) \quad \alpha(\Omega_{p^*}, f_{p^*}) = \frac{1}{1-\rho^2} + \varphi$$

註  $p^* \geq 0$  でなければならぬので (22) で与へる  $\lambda$  を用い得ない事がある。

之は Correlation Coefficient の大きさが  $\rho$  なる函数族に対して、Optimum Sampling System を近似的に与へるものである。

之を Graph で説明するなら、次の様である。(Graph は終項へ)  
横軸は  $\rho$ 、縦軸は  $C_p/C_f$  である。然らば任意の函数、依つて、Sampling System は多対一に此の平面上の一実で表現される。曲線群は Equi-efficiency  $\alpha$  を与へる Sampling System を表はす。

我々の知識は此の平面上の discrete な実の集りであるが、 $p^*$  の導入により、知識の範囲を斯る実を通り縦軸に平行な直線上に

迄拡大する事が可能となる。

こゝで此の直線に切する Equi-efficiency 曲線  $\alpha = \frac{1}{1-\rho^2}$  との切角が近似的に Optimum Sampling System を与へるのである。

四に於て横軸と原点と  $(\pm 1, 2)$  を通る直線上の System は Equally likely な Sampling System と同様な Efficiency を持つ System を表はしてある。

註 函数族  $\{P\}$  の correlation coefficient  $\rho$  の例へば linear form で correlation が maximum となる様にして  $P^*$  を導入すれば更に Efficient な System を与へる事は明らかである。

## § 7. 後書

以上で Sampling System の考へ方を説明したのであるが最後に一つだけ附言しておきたい。

所論から明かな様に (8) から  $P$  を決定する事が出来た。此の効果的な決定法に就いての研究が行はれなければならない。此の問題に関する御協力を期待する。

註 実例は Hansen - Hurwitz の考へを拡張した水野に依る

Sampling with probability proportionate to sizes が  
その一つである。之は統計数理研究所談話会。日本数学会に  
於て昨年報告した。何れ原稿にして発表する予定である。

統計数理研究所

廻町研究室にて

