

任意標本調査法 (三)

関 弥 三 郎

二 任意抽出法の理論

- (1) 標本平均分布
- (2) 確率分布、期望値計算
- (3) 標本推定の原理
- (4) 母集団の量的大いさの推定
- (5) 標本比例数分布
- (6) 標本推定の精度
- (7) 標本の大いさの決定
- (8) 母分散の推定
- (9) 標本抽出の諸方式

二、任意抽出法の理論

前に考察した母集団の構造を示す値(母数)を標本の構造を示す値(統計量)より推定するに当って、任意標本理論は母集団より同じ大いさの標本を可能な限

り、抽出構成する時、各標本より得られる統計量の分布(標本分布 sampling distribution)を求め、それと母数との關係を明らかにする事によって、現実に任意標本より得られた統計量はそのうちの一の値をとる事から、誤差の範圍を明示して母数を推定する事が出来るのである。以下母集団の平均値の推定を例にとつて、標本分布を求めそれによる標本推定の方式を明らかにらしめよう。

標本調査の實際に於て標本より推定すべき母数は主として平均値又は比例数であり、その他の母数が推定される場合もそれ自体の推定が目的ではなく、この平均値、比例数の推定の必要上求められる事が多い。故に以下の説明に於ては母平均及び母比例数の推定を中心に説明して行く事にする。

(1) 標本平均分布

母集団の平均値（母平均）の推定値としては、同じ性質の集団構造の簡約表章値である標本平均値を以てする事が考えられる。今母集団 π は N 個の単位より成り、各単位の有する量的標識を x_1, x_2, \dots, x_N とし、その平均値を \bar{x} 、分散を σ^2 とする。

$$\bar{x} = \frac{1}{N} \sum_{j=1}^N x_j, \quad \sigma^2 = \frac{1}{N} \sum_{j=1}^N (x_j - \bar{x})^2 \quad (2.1)$$

である。この母集団より n 個の単位を任意に抽出して構成した標本の各単位の量的標識を x_1', x_2', \dots, x_n' とし、その平均値を \bar{x}' 、分散を σ'^2 で表すと

$$\bar{x}' = \frac{1}{n} \sum_{j=1}^n x_j', \quad \sigma'^2 = \frac{1}{n} \sum_{j=1}^n (x_j' - \bar{x}')^2 \quad (2.2)$$

である。

茲に π は母集団に於ける単位の有する量的標識を表し、 x_j はそれより抽出構成された標本内の単位の持つ量的標識である。又 \bar{x} 、 σ^2 はそれぞれ母集団の平均値、分散であり、 \bar{x}' 、 σ'^2 は標本の平均値、分散を表す。このような母集団に於ける値と標本に於ける値との記号上の区別をよく弁える事は、任意標本理論を学ぶ上に於て極めて重要であ

る。

この標本平均値 \bar{x}' の標本分布を求めるのであるが、その状態は標本分布の平均値、分散等を計算し、分布の形を調べる事によつて規定する事が出来るのである。故に先づ標本平均分布の平均値を求めよう。

標本分布は母集団より可能な限り標本を構成する時に各標本より得られる統計量の分布であるが、茲に「可能な限りの標本構成」とは、 N 個の単位より n 個の単位を抽出し、次にその残り $(N-n)$ 単位より n 単位抽出して行つて N 個の単位がなくなる迄標本を構成する事、即ち n 個の単位がすべて異なる単位である如き標本の可能な限りの構成ではなくして、仮令 n 個の単位が全く同じであっても、その抽出の仕方が全く同じでないような標本、即ち抽出に順序を附けた時各単位の抽出される順序がすべて同じでない標本の可能な限りの構成である事は明らかである。しかればそのような標本の理論的に構成可能な数は、 N 個の単位の中から n 個取出す「順列」の数として求められ、故

に

$$N!P_n = N(N-1)\cdots(N-n+1)$$

通りである。

1) 若し単位の抽出に順序を附けないで考えると、標本を構成する n 個の単位のすべてが同じでないような標本 (従つて n 個の単位が全部異なる標本もあれば、只一個の単位のみを異にし残り $(n-1)$ 個の単位が同じであるような標本もある) の可能な限りの構成となり、その理論的な数は N 個の単位の中から n 個取出す「組合せ」の数として求められ

$${}^N C_n = \frac{{}^N P_n}{n!} = \frac{N(N-1)\cdots(N-n+1)}{n(n-1)\cdots 1}$$

通りである。

「可能な限りの標本の数」を C_n と通りとするならば、以下の説明に於て P_n の代りに C_n と置けばよい。(但し(2.6)の式の説明の場合は若干注意を要す。)

この P_n 組の標本の各々に就て求めた標本平均値 \bar{x} の平均は

$$\begin{aligned} \frac{1}{{}^N P_n} \sum_{k=1}^{N!P_n} \bar{x}'_k &= \frac{1}{{}^N P_n} \sum_{k=1}^{N!P_n} \left(\frac{1}{n} \sum_{j=1}^n x'_j \right) \\ &= \frac{1}{{}^N P_n} \sum_{k=1}^{N!P_n} \sum_{j=1}^n x'_j k \end{aligned} \quad (2.3)$$

任意標本調査法

$N!P_n$ (標本の数)	(標本単位数)			
	x'_{11}	x'_{12}	x'_{1n}
	x'_{21}	x'_{22}	x'_{2n}
	x'_{31}	x'_{32}	x'_{3n}

量 x_1, x_2, \dots, x_n のすべてが、同じ割合で含まれている筈であるから、この N 個の x_j の和が $\frac{n!P_n}{N}$ 組ある事になる。故に

$$A = \frac{n!P_n}{N} \sum_{j=1}^n x_j$$

と書替えられ、従つて(2.3)式は

$$\frac{1}{{}^N P_n} \sum_{k=1}^{N!P_n} \bar{x}'_k = \frac{1}{{}^N P_n} \sum_{k=1}^{N!P_n} \sum_{j=1}^n x_j k$$

$$= \frac{1}{N} \sum_{j=1}^n x_j = \bar{x} \quad (2.4) \quad [(2.1)より]$$

となる。即ち理論的な標本平均分布の平均値は母平均 \bar{x} に一致するのである。

次にその分散 $\sigma_{\bar{x}}^2$ を求めよう。分散は変量 (茲では \bar{x}) のその平均値 (2.4式より \bar{x}) よりの偏差の自乗の

平均であるから

$$\sigma_n^2 = \frac{1}{N P_n} \sum_{k=1}^{N P_n} (x'_k - \bar{x})^2$$

$$= \frac{1}{N P_n} \sum_{k=1}^{N P_n} x_k^2 - \bar{x}^2 \quad (2.5) \text{ [簡便計算式(6')より]}$$

第一項: $\frac{1}{N P_n} \sum_{k=1}^{N P_n} x_k^2$

$$= \frac{1}{N P_n} \sum_{k=1}^{N P_n} \left\{ \frac{1}{n} (x'_{1k} + x'_{2k} + \dots + x'_{nk}) \right\}^2$$

$$= \frac{1}{n^2 N P_n} \underbrace{\sum_{k=1}^{N P_n} \sum_{j=1}^n x'_{jk}^2}_{B} + \underbrace{\sum_{k=1}^{N P_n} \sum_{j \neq j'}^n x'_{jk} x'_{j'k}}_{C} \quad (2.6)$$

茲にBは(2.3)式のAに於て、 x_{jk} が自乗されている場合であるから

$$B = \frac{n N P_n}{N} \sum_{j=1}^n x_j^2$$

と書替えられる。Cは一の標本の x_k を構成するn個の單位を、二個宛組合せて得られる値の組 $(x'_{jh}, x'_{j'h})$ 、

$(j, j' = 1, 2, \dots, n)$ —— x_j の数は P_n 組ある —— の積 $x'_{jh} x'_{j'h}$

の総和 $\sum_{j, j'}^n x'_{jh} x'_{j'h}$ を、 P_n 組の標本すべてに就て求め

	n-1			
n	$x'_{11} x'_{12}$	$x'_{11} x'_{13}$	\dots	$x'_{11} x'_{1n}$
	$x'_{12} x'_{11}$	$x'_{12} x'_{13}$	\dots	$x'_{12} x'_{1n}$
			
n	$x'_{1n} x'_{11}$	$x'_{1n} x'_{12}$	\dots	$x'_{1n} x'_{1n-1}$
	$x'_{21} x'_{22}$	$x'_{21} x'_{23}$	\dots	$x'_{21} x'_{2n}$
			
			

それを合計したものであり、換言すれば $n P_n P_n$ 個の積 $x_j x_{j'}$ の和である。そしてその中には母集団に於けるN個の單位の變量 x_1, x_2, \dots, x_N の二二宛の可能な組合せ $(x_j, x_{j'})$ 、

数は P_n 組ある —— の積 $x_j x_{j'}$ のすべてが、同一割合で含まれてゐる筈であるから、 P_n 個の積 $x_j x_{j'}$ の和が、 $\frac{n P_n P_n}{N P_n} = \frac{n(n-1) P_n}{N(N-1)}$ 組もある事になる。従つて

$$C = \frac{n(n-1) N P_n}{N(N-1)} \sum_{j \neq j'}^n x_j x_{j'}$$

と書く事が出来る。故に(2.6)式は

$$\frac{1}{N P_n} \sum_{k=1}^{N P_n} x_k^2 = \frac{1}{n^2 N P_n} \left\{ n N P_n \sum_{j=1}^n x_j^2 \right.$$

$$\left. + \frac{n(n-1) N P_n}{N(N-1)} \sum_{j \neq j'}^n x_j x_{j'} \right\}$$

$$= \frac{1}{n N} \sum_{j=1}^n x_j^2 + \frac{n-1}{n N(N-1)} \sum_{j \neq j'}^n x_j x_{j'} \quad (2.7)$$

そして母集団分布に於て

$$\sigma^2 = \frac{1}{N} \sum_{j=1}^N (x_j - \bar{x})^2 = \frac{1}{N} \sum_{j=1}^N x_j^2 - \bar{x}^2$$

$$\therefore \frac{1}{N} \sum_{j=1}^N x_j^2 = \sigma^2 + \bar{x}^2 \quad (2.8)$$

$$\bar{x}^2 = \left\{ \frac{1}{N} \sum_{j=1}^N x_j \right\}^2 = \frac{1}{N^2} \left\{ \sum_{j=1}^N x_j + \sum_{j'=1}^N \sum_{j''=1}^N x_j x_{j''} \right\}^2$$

$$\therefore \sum_{j=1}^N \sum_{j'=1}^N x_j x_{j'} = N \bar{x}^2 - \sum_{j=1}^N x_j^2$$

$$= N \bar{x}^2 - N(\sigma^2 + \bar{x}^2) \quad [(2.8)より]$$

$$= N(N-1)\bar{x}^2 - N\sigma^2$$

なるため、これ等を(2.7)に代入する事により

$$\frac{1}{N^2 P_n} \sum_{k=1}^N x_k^2 = \frac{1}{n} (\sigma^2 + \bar{x}^2)$$

$$+ \frac{n-1}{nN(N-1)} \{ N(N-1)\bar{x}^2 - N\sigma^2 \}$$

$$= \frac{1}{n} (\sigma^2 + \bar{x}^2) + \frac{n-1}{n} \bar{x}^2 - \frac{n-1}{n(N-1)} \sigma^2$$

$$= \bar{x}^2 + \frac{N-n}{n(N-1)} \sigma^2$$

これを(2.5)式に代入して

$$\sigma^2_{\#} = \frac{\sigma^2}{n} \frac{N-n}{N-1} \quad (2.9)$$

となる。即ち理論的な標本平均分布の分散は母分散 σ^2

の $\frac{N-n}{n(N-1)}$ 倍である。この係数 $\frac{N-n}{n(N-1)}$ は1よりも小(狭)いため、標本平均の分布は母集団分布と平均値は同じであるが、その分布の範囲は母集団分布よりも狭いである。

① $n > 1$ なる限り $N-n < N-1 < n(N-1)$

(2.9)式より標本平均分布の標準偏差は

$$\sigma_{\#} = \frac{\sigma}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} \quad (2.10)$$

であり、これを平均値で除して相対化した変異係数 $C_{\#}$ は、母集団分布の変異係数を $c = \frac{\sigma}{\bar{x}}$ とすれば

$$C_{\#} = \frac{\sigma_{\#}}{\bar{x}} = \frac{c}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} \quad (2.11)$$

である。

そして(2.9)式に於て N が無限大ならば

$$\lim_{N \rightarrow \infty} \sigma^2_{\#} = \lim_{N \rightarrow \infty} \frac{1-N}{N-1} \frac{\sigma^2}{n} = \frac{\sigma^2}{n} \quad (2.12)$$

となる。故に母集団の大きさが無限大即ち無限母集団

の場合には、標本平均分布の分散は母集団の大きさに無関係に、標本の大きさに並に母分散の値によって決るのである。尚母集団の大きさを N が有限であつても、抽出単位数 n に比して極めて大であり、 $\frac{N-n}{N-1} \approx 1$ として取扱つても計算上差支えない程度の大きさであるならば(2.12)式を用いる事が出来る。従つて(2.9)式の $\frac{N-n}{N-1}$ を有限母集団修正 finite population correction 又は有限乗数 finite multiplier とす。

(2) 確率分布、期望値計算

今母集団 π より n 個の単位を抽出して標本 O を作り標本平均値 \bar{y} を計算する時、前項に考察した P_n 個の \bar{y} の何れか一の値をとる筈である。そして n 個の単位の抽出従つて標本の構成が無作為 at random になされるのであるから、 P_n 個の \bar{y} の何れがとられるかは全く偶然的に決り、従つて各 \bar{y} の出る可能性(即ち確率¹⁾)はその存在の割合(相対的度数)によって決るのであつて、この場合はすべて $\frac{1}{P_n}$ である。

1) 「確率」の定義は次の如くである。「一の事象 E が、すべて等可能であると考えられる n 個の可能な場合のうち m 個の場合に就て起るのであれば、当該事象 E の確率は $\frac{m}{n}$ と定義する。」

このような無作為操作の結果として x_1, x_2, \dots, x_k の何れかをとる変数 ξ があつて、 ξ が x_1, x_2, \dots, x_k をとる確率がそれぞれ p_1, p_2, \dots, p_k である時は、このような変数 ξ を確率変数 random variable とす。この x_1, x_2, \dots, x_k にそれぞれの確率 p_1, p_2, \dots, p_k を相対的度数として与えたものの分布を、 ξ の確率分布 probability distribution とす。そして無作為操作の結果現実に ξ がとる値を確率変数の実現値という。標本抽出の場合でいえば標本平均値 \bar{y} は確率変数であり、その実現値 \bar{y}_k ($k=1, 2, \dots, P_n$) は等確率 $\frac{1}{P_n}$ の一様確率分布をなすといえるのである。

そしてこの無作為操作を實際に多数回繰返す場合、 ξ の実現値の分布は予め理論的に判つてゐる ξ の確率分布を以て近似される事が、実験により經驗的に証明されるのである。(これを經驗的大数法則 empirical

law of large numbers という) 例えば骰子を投げる場合 1 から 6 迄の各目が出る可能性は、骰子が正確な等六面体で作られて居り投げ方に特定の傾向がない限り、すべて同一であると考えられるため、投骰の結果出る目の数は 1 から 6 迄の値をとる確率変数であり、確率 $\frac{1}{6}$ の一様確率分布をなすといえる。実際に骰子投げを多数回繰返し出た目の度数分布を作ると、それは略々 相対的度数 $\frac{1}{6}$ の一様分布をなし、投骰回数が増大するに従って益々 理論的な $\frac{1}{6}$ の一様確率分布に収斂する事が判るのである。従って母集団 π より大いさ n の標本 O を繰返して無作為に構成する時得られる標本平均値 \bar{x} の実現値の分布は、標本の数従って \bar{x} の数が増加するに連れて、相対的度数が前項に考察した \bar{x} の理論的な標本平均分布に等しくなつて行くといえるのである。

確率変数 ξ の確率分布の状態は度数分布の場合と同様に、その平均値、分散等を求め分布の形を調べる事によって規定する事が出来る。

確率変数 ξ の確率分布の (算術) 平均値を期望値 (又は期待値) expected val. μ といひ $E(\xi)$ と記す。従つて期望値は平均値の定義式 (2) より、確率変数 ξ のとり得る可能なすべての値 x_1, x_2, \dots, x_k に、各値をとる確率 p_1, p_2, \dots, p_k を乗じて合計する事によつて求められる。

$$E(\xi) = p_1 x_1 + p_2 x_2 + \dots + p_k x_k = \sum_{k=1}^k p_k x_k \quad (2.13)$$

1) 確率変数 ξ の確率分布の平均値を「期望値」というのは、それが平均して一回の無作為操作の結果実現すると期待し得る値であるからである。蓋し無作為操作の多数回 (例えば n 回) 反覆の結果実現する値の総和は、その実現値の分布が大数法則の作用によりその確率変数 ξ の理論的な確率分布を以て近似し得るのであるから

$$(n p_1) x_1 + (n p_2) x_2 + \dots + (n p_k) x_k$$

である。(但し $n p_k$ は n 個の実現値中の x_k の数) 従つて平均一回の無作為操作に於て得られるであろう値には

$$p_1 x_1 + p_2 x_2 + \dots + p_k x_k$$

を期待してよいであろうからである。

この確率変数の期望値計算は確率分布の状態の規定に於て重要な役割を演ずるのである。故に確率変数の期望値の計算に就て成立する諸関係を説明しよう。

先づ確率変数 ξ の自乗 ξ^2 も亦確率変数であつて、そ

の期望値は ϵ_i のとり得るすべての値 x_i ($i=1, 2, \dots, k$)の自乗と、各値をとる確率 p_i ($i=1, 2, \dots, k$)の積の総和であるから

$$E(\epsilon^2) = \sum_{i=1}^k p_i x_i^2 \quad (2.14)$$

一般に確率変数 ϵ の函数 $f(\epsilon)$ の期望値は

$$E\{f(\epsilon)\} = \sum_{i=1}^k p_i f(x_i) \quad (2.15)$$

で定義される。

次に二の確率変数 ϵ 、 η の和 $\epsilon+\eta$ も亦確率変数であつて、その期望値は ϵ の期望値と η の期望値との和に等し ζ 。即ち

$$E(\epsilon+\eta) = E(\epsilon) + E(\eta) \quad (2.16)$$

これを証明しよう。確率変数 ϵ は値 x_1, x_2, \dots, x_k を確率 p_1, p_2, \dots, p_k を以てとり、 η は値 y_1, y_2, \dots, y_l を確率 q_1, q_2, \dots, q_l を以てとるとする。すると $\epsilon+\eta$ は x_i+y_j ($i=1, 2, \dots, k; j=1, 2, \dots, l$)の kl 個の値をとり得る事となる。新確率変数 $\epsilon+\eta$ が値 x_i+y_j をとる確率を $P(x_i, y_j)$ と表すと、 $\epsilon+\eta$ の

期望値は期望値の定義により

$$E(\epsilon+\eta) = \sum_{i=1}^k \sum_{j=1}^l P(x_i, y_j) \cdot (x_i+y_j)$$

$$\begin{aligned} &= \sum_{i=1}^k \sum_{j=1}^l P(x_i, y_j) \cdot x_i + \sum_{i=1}^k \sum_{j=1}^l P(x_i, y_j) \cdot y_j \\ &= \sum_{i=1}^k x_i \underbrace{\left\{ \sum_{j=1}^l P(x_i, y_j) \right\}}_{p_i} + \sum_{j=1}^l y_j \underbrace{\left\{ \sum_{i=1}^k P(x_i, y_j) \right\}}_{q_j} \end{aligned}$$

ただし $\sum_{j=1}^l P(x_i, y_j) = P(x_i, y_1) + P(x_i, y_2) + \dots + P(x_i, y_l)$ であり、 x_i が或る値 x_i をとる時 η が y_1 から y_l 迄可能なすべての値をとる確率の合計であるから、結局 η の値に無関係に、 x_i が x_i をとる確率 p_i に等しいからである。全く同様にして $\sum_{i=1}^k P(x_i, y_j) = q_j$ がいえぬ。故に

$$E(\epsilon+\eta) = \sum_{i=1}^k p_i x_i + \sum_{j=1}^l q_j y_j = E(\epsilon) + E(\eta)$$

(証明終り)

1) 例えば二個の骰子を投げて出る目の和を考えると、それは2—12の各値をそれぞれ特定の確率を以てとる変数であるから、これ亦確率変数である。

この関係は n 個の確率変数 $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ の和に拡張する事が出来るのであつて、その場合は次の式が成立つのである。

$$E(\epsilon_1 + \epsilon_2 + \dots + \epsilon_n) = E(\epsilon_1) + E(\epsilon_2) + \dots + E(\epsilon_n) \quad (2.17)$$

この証明も(2.16)の証明と同様に行う事が出来る

ので省略する。

次に二の確率変数 x_i の積 $\prod x_i$ も亦確率変数であるが、この期望値 $E(\prod x_i)$ は必ずしも $\prod E(x_i)$ の期望値 $E(\prod x_i)$ と $\prod E(x_i)$ の積 $E(x_i)E(x_j)$ に等しくはないのであつて、ただ x_i と x_j が相互に独立 (無関係) なる場合にのみ

$$E(\prod x_i) = E(x_i)E(x_j) \quad (2.18)$$

となるのである。これは次の様にして証明される。今 x_i は値 x_1, x_2, \dots, x_k を確率 p_1, p_2, \dots, p_k を以てとり、 x_j は値 y_1, y_2, \dots, y_l を確率 q_1, q_2, \dots, q_l を以てとるとする。すると $\prod x_i$ は x_i, y_j ($i=1, 2, \dots, k; j=1, 2, \dots, l$) の kl 個の値をとり、 $\prod x_i$ が x_i, y_j なる値をとる確率は、 x_i と y_j とが相互に独立であるから、 $p_i q_j$ である。ただし x_i と y_j とが相互独立、即ち x_i

をとるのと y_j をとるとは無関係であるため、 x_i が x_i をとる時に y_j をとる確率は q_j のとる値の如何に拘らず q_j であり、或は又 y_j が y_j をとる時に x_i が x_i をとる確率は p_i がとる値に關係なく p_i であるから、 x_i を x_i を、 y_j が y_j を同時にとる確率は、確率の乗法定理²⁾に

より $p_i q_j$ であるからである。故に $\prod x_i$ の期望値は

$$E(\prod x_i) = \sum_{i=1}^k \sum_{j=1}^l p_i q_j x_i y_j = \sum_{i=1}^k p_i x_i \sum_{j=1}^l q_j y_j = E(x_i) E(y_j) \quad (2.19)$$

〔豊田泰三〕

1) 例えば 1 から 10 迄の数字を記入した十個の球が入っている壺の中から、引続いて二個の球を抽出する時は、最初の球の数字が例えば 3 であるならば、二回目の球の数字は決して 3 ではあり得ず 3 以外の数字であるから、一回目の数字と二回目の数字とは相互に無関係 (独立) ではないのである。しかるに最初に抽出した球を元へ戻してから二回目を抽出するならば、二回目の数字は一回目の数字と同様 1—10 の何れかの値であるから、両者は相互に無関係 (独立) である。

2) 確率の乗法定理は次の如くである。「事象 E_1 の現れる確率が p_1 であり、事象 E_2 が現れた時に事象 E_1 が現れる確率が p_2 であるとすれば、事象 E_1 、 E_2 が同時に現れる確率は $p_1 \times p_2$ である。」ただし E_2 は E_1 が現れた後でなければ現れないのであるから、 E_1 の現れる可能性 p_1 の上に E_2 の現れる可能性 p_2 が被さつて始めて、 E_1 、 E_2 の併起する可能性となるからである。

3) p_i 、 x_i は j の計算に於ては常数となり、 j に就ての和 $\sum_{j=1}^n$ の外に約し出せるからである。

一般に n 個の確率変数 x_1, x_2, \dots, x_n が相互に独立ならば

$$E(x_1 x_2 \dots x_n) = E(x_1) E(x_2) \dots E(x_n) \quad (2.19)$$

が成立する。何となれば ξ_1, \dots, ξ_n が相互に独立ならば ξ_1, \dots, ξ_n とも独立であるから、(2.18)式より $E(\xi_1 \dots \xi_n) = E(\xi_1)E(\xi_2) \dots E(\xi_n)$ である。これを繰返す事による $E(\xi_1 \dots \xi_n) = E(\xi_1) \dots E(\xi_n)$ が得られるからである。

又確率変数 ξ に常数 a を乗じた値 $a\xi$ も確率変数である。その期望値は ξ の期望値の a 倍である。

$$E(a\xi) = aE(\xi), \quad a = \text{const.} \quad (2.20)$$

なんととなれば

$$E(a\xi) = a_1ax_1 + a_2ax_2 + \dots + a_kax_k \\ = a(a_1x_1 + a_2x_2 + \dots + a_kx_k) = aE(\xi)$$

【証明終り】

常数 a の期望値は a に等しい。即ち

$$E(a) = a \quad (2.21)$$

なんととなれば(2.13)式に於て $\xi_i = a$ 従って $x_i = a, (i=1, 2, \dots, k)$ と置くこと

$$E(a) = p_1a + p_2a + \dots + p_k a = a(p_1 + p_2 + \dots + p_k) = a$$

【∴ 確率は一種の相対的度数であるから(前講P.112参照)】 【証明終り】

さて次に確率分布の分散並にその計算に於て成立す

る諸関係を説明しよう。確率変数 ξ の確率分布の分散 $V(\xi)$ 、標準偏差を σ_ξ と表すならば、標準偏差の定義式

$$(5) \text{より}$$

$$V(\xi) = \sigma_\xi^2 = \sum_{i=1}^k p_i(x_i - E(\xi))^2$$

これは ξ の函数 $(\xi - E(\xi))^2$ の期望値であるため、(2.15)式より

$$V(\xi) = \sigma_\xi^2 = E(\xi - E(\xi))^2 \quad (2.22)$$

と書ける。(2.22)式は次のように変形する事が出来る。

$$V(\xi) = E(\xi - E(\xi))^2 = E(\xi^2 - 2\xi E(\xi) + (E(\xi))^2) \\ = E(\xi^2) - 2E(\xi)E(\xi) + (E(\xi))^2 \quad \left[\begin{array}{l} \therefore E(\xi) \text{ は 常数で} \\ \text{あるため(2.20)} \end{array} \right] \\ = E(\xi^2) - (E(\xi))^2 \quad (2.23)$$

即ち $V(\xi)$ は ξ の自乗の期望値よりも ξ の期望値の自乗を引いたものに等しいのである。(これは(6)式に相当する)

又(2.23)式より

$$E(\xi^2) = V(\xi) + (E(\xi))^2 \quad (2.24)$$

故に ξ の自乗の期望値は、 ξ の分散とその期望値の自乗との和に等しいのである。この関係はよく用いられる。

若し確率変数 ξ に常数 a が掛っているならば

$$V(a\xi) = a^2 V(\xi) \quad (2.25)$$

である。なんとすれば

$$\begin{aligned} V(a\xi) &= E\{(a\xi - E(a\xi))^2\} = E\{a^2(\xi - aE(\xi))^2\} \\ &= a^2 E\{\xi - E(\xi)\}^2 = a^2 V(\xi) \end{aligned}$$

【証明終り】

ところが相互に独立な確率変数ならば

$$V(\xi + \eta) = V(\xi) + V(\eta) \quad (2.26)$$

これを証明するに

$$\begin{aligned} V(\xi + \eta) &= E\{(\xi + \eta) - E(\xi + \eta)\}^2 \\ &= E\{(\xi - E(\xi)) + (\eta - E(\eta))\}^2 \\ &= E\{(\xi - E(\xi))^2 + (\eta - E(\eta))^2 + 2(\xi - E(\xi))(\eta - E(\eta))\} \\ &= E(\xi - E(\xi))^2 + E(\eta - E(\eta))^2 + 2E\{(\xi - E(\xi))(\eta - E(\eta))\} \end{aligned}$$

しかるに ξ と η とは相互独立なるため、(2.18)式より

$$E\{(\xi - E(\xi))(\eta - E(\eta))\} = E(\xi - E(\xi))E(\eta - E(\eta)) = 0$$

$$\left[\begin{array}{l} \therefore E(\xi - E(\xi)) = E\xi - E\xi = 0, \\ \text{同様にして } E(\eta - E(\eta)) = 0 \end{array} \right]$$

$$\therefore V(\xi + \eta) = E(\xi - E(\xi))^2 + E(\eta - E(\eta))^2 = V(\xi) + V(\eta)$$

【証明終り】

任意標本調査法

一般に n 個の確率変数 $\xi_1, \xi_2, \dots, \xi_n$ が相互に独立ならば

$$V(\xi_1 + \xi_2 + \dots + \xi_n) = V(\xi_1) + V(\xi_2) + \dots + V(\xi_n) \quad (2.27)$$

これは (2.26) 式の証明と同様にして証明されるので省略する。

尚確率変数 ξ の確率分布の標準偏差 σ_ξ をその期望値

$E(\xi)$ で除して相対化した値を、 ξ の変異係数といひ C_ξ と表す

$$C_\xi = \frac{\sigma_\xi}{E(\xi)} \quad (2.28)$$

二の確率変数 ξ, η の相関確率分布に於ては、 ξ, η の間の共変量 $\text{Cov}(\xi, \eta)$ 及び相関係数 $\rho_{\xi, \eta}$ が求められる。

それに就ては後に必要な箇処に於て述べる事にす。

る。

註 (2.16)(2.18)(2.21) 式の証明の過程に於て確率に就ての計算を直観的に説明した箇所があるが、その正確な証明は確率書を参照されたい。

任意標本理論に於ては確率分布たる標本分布の状態を調べるのに、その期望値、分散等を求めねばならぬのであるが、以上に述べた期望値計算の諸公式によ

ると、それは極めて容易に計算する事が出来る。前項に於て既に計算した標本平均分布の期望値及び分散を、今一度この方法によって求めてみよう。

その前に母集団 π より一個の単位を抽出する時得られる値 x の標本分布の期望値と分散を計算して置くこと便利である。 π より一個の単位を抽出する時得られる値は x_1, x_2, \dots, x_N の何れかであり、且任意抽出であるためどれもその抽かれる可能性(確率)は等しく $\frac{1}{N}$ である。抽出された単位の変量 x_j が x なる値をとる確率を $P_j\{x' = x_j\}$ と書くならば

$$P_j\{x' = x_1\} = P_j\{x' = x_2\} = \dots = P_j\{x' = x_N\} = \frac{1}{N}$$

従つて

$$E(x') = \sum_{j=1}^N x_j P_j\{x' = x_j\} = \frac{1}{N} \sum_{j=1}^N x_j = \bar{x} \quad (2.29)$$

$$\begin{aligned} V(x') &= E(x' - \bar{x})^2 = \sum_{j=1}^N (x_j - \bar{x})^2 P_j\{x' = x_j\} \\ &= \frac{1}{N} \sum_{j=1}^N (x_j - \bar{x})^2 = \sigma^2 \end{aligned} \quad (2.30)$$

故に x' の確率分布の期望値は母平均に等しく、分散は母分散に等しいのである。即ち x' の標本分布は母集団分布に一致するのである。

さて標本平均分布の期望値は

$$E(\bar{x}) = E\left(\frac{1}{n} \sum_{j=1}^n x_j'\right) = \frac{1}{n} \sum_{j=1}^n E(x_j') \quad (2.20) \quad (2.17) \quad (2.18)$$

茲に (x_j') は母集団 π より一個抽出する時得られる値の期望値である。故に(2.29)式より

$$E(x_j') = \frac{1}{n} \sum_{j=1}^n \bar{x} = \bar{x} \quad (2.31)$$

分散は

$$V(\bar{x}) = E(\bar{x}' - \bar{x})^2 = E(x_j'^2) - \bar{x}^2 \quad [(2.28)(2.17)]$$

$$\text{第一項: } E(x_j'^2) = E\left(\frac{1}{n} \sum_{j=1}^n x_j'^2\right)^2$$

$$= \frac{1}{n^2} E\left(\sum_{j=1}^n x_j'^2 + \sum_{\substack{j, j' \\ j \neq j'}}^n x_j' x_{j'}'\right)$$

$$= \frac{1}{n^2} \left\{ \sum_{j=1}^n E(x_j'^2) + \sum_{\substack{j, j' \\ j \neq j'}}^n E(x_j' x_{j'}') \right\} \quad (2.32)$$

右辺第一項の $E(x_j'^2)$ は、母集団 π より只一個抽出した時得られる値の自乗の標本分布の期望値である。故に

$$E(x_j'^2) = \sum_{j=1}^N x_j^2 P_j\{x' = x_j\} = \frac{1}{N} \sum_{j=1}^N x_j^2$$

又右辺第二項の $E(x_j' x_{j'}')$ は、 π より二個引続いて抽出する時得られる値の組 (x_1', x_2') の積 $x_1' x_2'$ の標本分布の期望値である。そして π より二個引続いて抽出する事によって得られる値の組の理論的な数は、 N 個の

単位中より二個の単位を取出す「順列」の数として得られるため、 ${}_N P_2 = N(N-1)$ 通りである。実際に二個の単位の任意抽出によって得られる値の組はこの ${}_N P_2$ 組の何れかであり、且その各々は抽出される可能性(確率)はすべて等しくから

$$P_2\{x_1 = x_j, x_2 = x_{j'}\} = \frac{1}{N(N-1)}, \quad (j, j' = 1, 2, \dots, N)$$

である。従って

$$\begin{aligned} E(x_1, x_2) &= \sum_{j \neq j'}^N \sum_{j' \neq j}^N x_j x_{j'} P_2\{x_1 = x_j, x_2 = x_{j'}\} \\ &= \frac{1}{N(N-1)} \sum_{j \neq j'}^N \sum_{j' \neq j}^N x_j x_{j'} \end{aligned}$$

故に式は

$$\begin{aligned} E(x^2) &= \frac{1}{n^2} \sum_{j=1}^n \left(\frac{1}{N} \sum_{j=1}^n x^2_j \right) \\ &\quad + \sum_{j \neq j'}^n \frac{1}{n} \left(\frac{1}{N(N-1)} \sum_{j \neq j'}^N \sum_{j' \neq j}^N x_j x_{j'} \right) \\ &= \frac{1}{n^2} \left\{ \frac{n}{N} \sum_{j=1}^n x^2_j + \frac{n(n-1)}{N(N-1)} \sum_{j \neq j'}^N \sum_{j' \neq j}^N x_j x_{j'} \right\} \\ &= \frac{1}{n} \sum_{j=1}^n x^2_j + \frac{n-1}{nN(N-1)} \sum_{j \neq j'}^N \sum_{j' \neq j}^N x_j x_{j'} \end{aligned}$$

これは(2.7)式の外ならぬ。従って前と同様にして

$$E(x^2) = \bar{x}^2 + \frac{N-n}{n(N-1)} \sigma^2$$

任意標本調査法

故に

$$V(x) = \frac{\sigma^2}{n} \frac{N-n}{N-1} \quad (2.33)$$

1) $\sum_{j \neq j'}^n 1 = n(n-1)$ 、ただし抽出された n 個の単位を二個宛(順序を附けて)組合せる場合の数は ${}_n P_2 = n(n-1)$ 通りであるからである。

最後に確率分布たる標本分布の形は、母集団の分布の形並に標本として抽出される単位の数及び母数を推定するための統計量の函数形によって決るのであって、それには正規分布、二項分布、Poisson 分布、t 分布、 χ^2 分布、F 分布、Z 分布等がある。しかし標本平均値及び標本比例数の分布は、標本の大きさ n が充分に大であるならば(即ち大標本の場合は)、母集団の分布形の如何に拘らず正規分布に近い分布をなす事が数学的に証明されるのである。社会統計調査に於ては抽出単位数は殆ど茲にいう大標本の場合であるから、本標分布は正規分布をなすものとして取扱えばよいのである。かくて前項に考察した標本平均分布は正規分布をなしているという事が出来るのである。

1) 標本平均分布は、母集団の大きさ N が標本の大きさ n

に比して相当大きくその分布が極度に非対称分布でない限り、 $\frac{1}{\sqrt{20}}$ の時は正規分布と看做し得る事が経験的に知られているのである。特に母集団分布が正規分布をなす時は、標本の大きさの如何に拘らず、標本平均分布は常に完全な正規分布をなすのである。

標本比例数分布は $\frac{1}{\sqrt{20}}$ であれば正規分布と見てよい事が数値計算によって判るのである。

そして確率変数 ξ の確率分布が正規形である時は、正規分布の特徴により

$$\left\{ \begin{array}{l} E(\xi) + a\sigma \\ E(\xi) + 2a\sigma \\ E(\xi) + 3a\sigma \end{array} \right\} \text{内にある } \omega \text{ の実現値が有す} \left\{ \begin{array}{l} 0.68268 \\ 0.95450 \\ 0.99730 \end{array} \right.$$

である。従つて一回の無作為操作の結果 ω が値 ω_0 をとつたとすれば、それが区間 $E(\xi) + 2a\sigma$ 外にある確率は5%弱に過ぎず、95%強の確率を以て $E(\xi) + 2a\sigma$ 内にあるという事が出来るのである。

1) 仮令確率分布が正規形でなく非対称分布をなす場合であつても、チェビシェフの定理により、区内 $E(\xi) + 10a\sigma$ 内にある ω の実現値の有する確率は $(1 - \frac{1}{10^2})$ より大である。

任意標本による時は誤差の少い母数の推定値が得られ尚且誤差の範囲を規定し得るのは、その標本推定値

がこのような確率変数の実現値としての性格を有するからである。次に項を改めて任意標本による標本推定の方法を説明しよう。

(3) 標本推定の原理

以上により明らかなる如く確率分布としての標本平均分布の期望値は母平均に等しく、その標本平均分布は現実と同じ大きさの任意標本を多数構成する時得られる標本平均値の分布を近似的に表すものであるため、多数回任意標本調査を行つて得られた標本平均値を更に平均する事によつて、母平均の値を略々正確に知る事が出来るのである。

このように同じ方法で繰返し構成された標本より得られる標本推定値の平均が母数に等しい場合、それは不偏 unbiased であるといふ、その推定値を不偏推定値 unbiased estimate といふ。そして標本推定値の平均が母数に一致しなう時はその差を偏り bias とし、そのような推定値を偏りある推定値 biased estimate といふ。標本推定値が不偏推定値の場合は母数に等しい値を得る事が方法的に可能であるが、標本推定値が偏りある推定値の時はその

は不可能である。故に標本推定値は他の条件(推定の精度、計算の難易等)が同じであるならば、偏りあるものよりも不偏であるものの方がよい推定値である事はいふ迄もないであろう。

このように標本平均は母平均の不偏推定値であるが、実際上は標本調査は只一回行われるのみであつて多数回繰返して行われるものではないのであるから、只一の標本平均値を以て母平均の推定値としなければならず、従つて標本推定値は当然に誤差を有するのである。しかしながら任意標本より求めた標本推定値は確率率と看做し得るから、標本平均分布の期望値即ち母平均を中心にして、その標準偏差の例えば二倍の範囲外の値である事は極めて稀であり、殆どその内部の値であるとしてよいのである。従つてこの標本平均分布の標準偏差の±2倍の区間を以て推定値の誤差の範囲と規定する時は、殆どその内部に母平均を含んでいる事となるのである。

今母集団 π より n 個の単位を任意に抽出して一の標本 O を構成し、それより標本平均値 \bar{x}_0 を得たとする。

任意標本調査法

この \bar{x}_0 は期望値 μ 、分散 $\frac{\sigma^2}{n}$ の略々正規分布をなす標本平均分布の何れか一の値をとるのであるが、標本の構成即ち n 個の単位の抽出が全く偶然的になされたものであるならば、その値が

$$\left. \begin{array}{l} \bar{x} \pm \sigma_{\bar{x}} \\ \bar{x} \pm 2\sigma_{\bar{x}} \\ \bar{x} \pm 3\sigma_{\bar{x}} \end{array} \right\} \begin{array}{l} \text{内に在る確率は} \\ 95.45\% \\ 99.73\% \end{array}$$


であるという事が出来るのである。従つて逆にその標本平均値 \bar{x}_0 に $\pm \sigma_{\bar{x}}$ 、 $\pm 2\sigma_{\bar{x}}$ 、 $\pm 3\sigma_{\bar{x}}$ の誤差の幅を附すならば、

$$\left. \begin{array}{l} \bar{x} \pm \sigma_{\bar{x}} \\ \bar{x} \pm 2\sigma_{\bar{x}} \\ \bar{x} \pm 3\sigma_{\bar{x}} \end{array} \right\} \begin{array}{l} \text{区内に母平均} \mu \text{ を含む確率は} \\ 95.45\% \\ 99.73\% \end{array}$$

であるといえるであらう。

従つて若し大いさ n の任意標本を実際に100回構成し100個の標本平均値を得るならば、略々そのうち95個は区間 $(\bar{x}_0 - 2\sigma_{\bar{x}}, \bar{x}_0 + 2\sigma_{\bar{x}})$ 内の値であり、5個がその外部の値であるに過ぎないであらう。そして各標本より得られた標本平均値に $\pm 2\sigma_{\bar{x}}$ の幅を見込むならば、その区間の中に母平均 μ を含む場合が95回あり、 \bar{x}_0 がその区間外にある場合が5回あるであらう。(第一回参照)

第一図 信頼区間



かくて一の任意標本より求

めた標本平均値に普通 $\pm 2\sigma$

の誤差を附記して、信頼度 95

%の母平均の推定値となすの

である。例えば世帯数 26 万の

或る都市に於て、一世帯当り

平均家計費を調査するために

130 世帯を抽出して 1/2,000 の

標本を構成し、家計調査の結果

果平均家計費 18,500 円を得た

とする。母集団に於ける家計費分布の標準偏差の推定

値を 10,300 円とすると、 $\sigma_{\bar{x}}$ は次のようになる。この場

合は N が n に比して極めて大であるため有限母集団修

正は略 $\sigma_{\bar{x}}$ に等し。故に

$$\sigma_{\bar{x}} = \frac{10,300}{\sqrt{130}} = 903.3714$$

従つてこの都市の平均家計費は 18,500 円 $\pm 2 \times 903.3714$

即ち 16,633 円 \sim 20,377 円の間にあるという事が出来、

その真なる確率は 95% である。

このような標本推定値が一定の確率に於て出現する区間を信頼区間 confidence interval といひ、その限界を信頼限界 confidence limit その区間内に推定値がある確率を信頼係数 confidence coefficient とす。

以上のようにして任意抽出法による時は、一定の信頼度に於て信頼区間（誤差の範囲）を明示して、母数の推定をなす事が出来るのである。

- 1) この値は (2.47) 式によつて推定される。

(4) 母集団の量的大いさの推定

母集団の量的大いさ即ち母集団を構成する単位の変量の総和は、平均値に母集団の単位総数を乗する事によつて求める事が出来る。ただし平均値はすべての単位の変量の総和を単位総数で除した値であるからである。(1式参照) 従つて母平均の推定値に母集団の単位総数 N を乗する事によつて、母集団の量的大いさ $X = \sum_{i=1}^N x_i$ を推定する事が出来る。 X の推定値を \bar{X} と表すと

$$X^2 = N \bar{x}^2 = \frac{N}{n} \sum_{j=1}^n x_j^2 \quad (2.34)$$

この推定値は不偏である。

$$E(X^2) = NE(\bar{x}^2) = N \bar{x}^2 \quad [(2.31)より]$$

= X

その分散及び変異係数は次の如くである。

$$V(X^2) = N^2 V(\bar{x}^2) = N^2 \frac{N-n}{N-1} \frac{\sigma^2}{n} \quad (2.35)$$

[(2.33)より]

$$C_{X^2} = N \frac{\sqrt{\frac{N-n}{N-1}} \frac{\sigma}{\sqrt{n}} \frac{1}{X}}{\sqrt{\frac{N-n}{N-1}} \frac{\sigma}{\sqrt{n}} \frac{1}{N \bar{x}}} = N \frac{\sqrt{\frac{N-n}{N-1}} \frac{\sigma}{\sqrt{n}} \frac{1}{X}}{\sqrt{\frac{N-n}{N-1}} \frac{\sigma}{\sqrt{n}} \frac{1}{N \bar{x}}} \quad (2.36)$$

(2.36)式は(2.11)式と同じである。(2.36)式を導く過程より明らか
な如く、一般に $C_{X^2} = C_{\bar{x}^2}$ である。

(5) 標本比例数分布

以上は統計集団の量的構造の簡約表章値である平均値の標本推定であった。次に統計集団の質的構造の簡約表章値である比例数の標本推定を考察しよう。標本推定の方式は第三項に考察した平均値の推定の場合と全く同じであるため、不偏な標本推定値を求めその標本分布の分散式を導けばよいのである。

任意標本調査法

推定すべき比例数は母集団に於ける問題たる標識 α を有する単位の存在の割合であるから、それを標本より推定せんとする時は、標本に於ける標識 α を有する単位の割合即ち標本比例数を以てすべきであろう。従って標本比例数の分布を調べねばならないのであるが、その場合前講「母集団分布(3)」で述べたように統計集団の質的構造に就ても、その存在割合を知らんとする標識に1、その他の標識に0なる値を与る事によって量的構造化し得るのであるから、この変換によって標本比例数分布は前述の標本平均分布の特別の場合として容易に求める事が出来るのである。

今母集団 π の単位総数 N のうち N_1 が標識 α を有し、残り N_2 が α 以外の標識を持って居りそれぞれの割合を $p \left(= \frac{N_1}{N} \right), q \left(= \frac{N_2}{N} \right)$ とする。この母集団より n 個の単位を任意に抽出して構成した標本のうち n_1 個が標識 α を、残り n_2 個が α 以外の標識を有し、それぞれの割合を $p' \left(= \frac{n_1}{n} \right), q' \left(= \frac{n_2}{n} \right)$ とする。ここで α 標識を有する単位に変量 $x = 1$ 、 α 以外の標識を有する単位

に变量 α のを与えると、母集団 π は 0, 1 のみの変量を有する単位の集合となり、その平均値は α 標識の割合 q に等しく、分散は p と α の以外の標識の割合 q との積 pq となる。

$$\bar{x} = \alpha, \quad \sigma^2 = pq$$

標本のも変量 0, 1 のみを有する単位の集合となるため、その平均値及び分散は同様に

$$\bar{x} = p', \quad s^2 = p'q'$$

となる。

1) これは次のようにして証明される。

$$\bar{x} = \frac{1}{N} \sum_{j=1}^{N_1} x_j = \frac{1}{N} \left\{ \sum_{j=1}^{N_1} 1 + \sum_{j=1}^{N_2} 0 \right\} = \frac{N_1}{N} = p$$

$$\sigma^2 = \frac{1}{N} \sum_{j=1}^{N_1} (x_j - \bar{x})^2 = \frac{1}{N} \left\{ \sum_{j=1}^{N_1} (1 - p)^2 + \sum_{j=1}^{N_2} (0 - p)^2 \right\}$$

$$= \frac{1}{N} (N_1 p^2 + N_2 p^2) = pq^2 + q p^2 = pq(q + p) = pq$$

【証明終り】

従って標本比例数分布は標本平均分布に於て、 \bar{x} , σ^2 , \bar{y} の代りに p , pq , p' を代入すればよい。先づ標本比例数分布の期望値は (2.31) 式より

$$E(p') = p \quad (2.37)$$

であり、故に標本比例数は母比例数の不偏推定値であ

る。次に分散、標準偏差は (2.33) 式より

$$V(p') = \frac{pq}{n} \frac{N-1}{N-1} \quad (2.38)$$

$$\sigma_{p'} = \sqrt{\frac{pq}{n} \frac{N-1}{N-1}} \quad (2.39)$$

変異係数は、母変異係数が $c = \frac{\sigma}{\bar{x}} = \sqrt{\frac{pq}{\alpha}} = \sqrt{\frac{pq}{p}}$ なるため、(2.11) 式より

$$c_{p'} = \sqrt{\frac{q}{np} \frac{N-1}{N-1}} \quad (2.40)$$

である。

母比例数の推定値 p' に母集団単位総数 N を乗ずる事によつて、母集団の α 標識の単位数 N_1 を推定する事が出来る。それは母集団に於ける標識 α の比例数は、 α を有する単位の数を総単位数で除した値であるからである。 N_1 の推定値を N_1' とすると

$$N_1' = N p' \quad (2.41)$$

これは不偏推定値である。

$$E(N_1') = NE(p') = N p = N_1$$

その分散及び変異係数は

$$V(N_1') = N^2 V(p') = N^2 \frac{pq}{n} \frac{N-1}{N-1} \quad (2.42)$$

$$c_{N_1'} = N \sqrt{\frac{q}{N-1} \frac{pq}{n} \frac{N-1}{N-1}} = \sqrt{\frac{q}{np} \frac{N-1}{N-1}}$$

A候補	26.7% (= p_1')
B候補	17.9% (= p_2')
C候補	13.6%
未定	41.8%

(2.43) 式は (2.40) 式と同じであるため $C_p = C_{N_1} + C_{N_2}$ 。

例えば某市の市長選挙に際して投票日三日前に60万の有権者より600人を抽出して、A、B、C何れの候補者に投票するかを調査し上の結果を得たとす。A候補の推定得票数 N_1' は

$$N_1' = 600,000 \times 0.267 = 160,200$$

その誤差の範囲は、母標準偏差の推定値を0.442とする。

$$\sigma_{N_1'} = \sqrt{\frac{pq}{n} \frac{N-n}{N-1}} = \sqrt{\frac{pq}{n}} = \frac{0.442}{\sqrt{600}} = 0.0180$$

〔∵ N が n に比して極めて大なるため〕

$$\therefore N_1' \pm 2\sigma_{N_1'} = N_1' \pm 2N\sigma_{p_1'}$$

$$= 160,200 \pm 2 \times (600,000 \times 0.018) = 138,600 \sim 181,800$$

次点B候補の推定得票数 N_2' の誤差の限界は、母標準偏差の推定値を0.383とする。

$$N_2' = 600,000 \times 0.179 = 107,400$$

$$\sigma_{N_2'} = \frac{0.383}{\sqrt{600}} = 0.0156$$

任意標本調査法

〔∵ $N_1' = N_1 p_1'$ なるため〕 (2.43)

$$\therefore N_2' \pm 2\sigma_{N_2'} = N_2' \pm 2N\sigma_{p_2'}$$

$$= 107,400 \pm 2 \times (600,000 \times 0.0156) = 88,880 \sim 126,120$$

従ってB候補の最高得票数はA候補の最低得票数に及ばないため決戦投票は行われず、結局A候補が13.9万票—18.1万票を得て当選するものと、真なる確率95%で推定されるのである。

1) この値は(2.51)式によって推定される。但しこの場合は N, n が相当の大であるので $\frac{N-1}{N} \approx 1, \frac{n-1}{n} \approx 1$ 従って

$$\begin{aligned} \frac{N-1}{N} \frac{n}{n-1} &= \sqrt{\frac{p_1'q_1' \cdot p_2'q_2'}{pq}} = \sqrt{\frac{p_1'q_1'}{pq} \cdot \frac{p_2'q_2'}{pq}} = 0.442 \\ &= \sqrt{0.267 \times 0.733} = 0.442 \end{aligned}$$

$$2) \sqrt{\frac{p_2'q_2'}{pq}} = \sqrt{0.179 \times 0.821} = 0.383, \quad q_2' = 1 - p_2'$$

(6) 標本推定の精度

標本推定値の母数よりの偏差は標本誤差であるが、現実には標本調査の結果如何なる誤差が現れるかは偶然に決るのであり、且推定値が不偏である場合は多数回の調査の繰返しによって相殺され得る誤差であるから、それは偶然誤差という事が出来る。しかしながら推定値が偏りを有するものなる場合は、標本誤差はこ

の偶然誤差のみならず、偏り(方法上、どうしても消す事の出来ない誤差)をも含んでいると見なければならぬ。

不偏推定値の標本分布の標準偏差(及び分散、変係

数)は、このような標本推定値の「誤差の分布」の範囲を表す値と見る事が出来るのであって、故にそれを

標準誤差 standard error (及び誤差分散、誤差変異係

数)という。標準誤差が小さい時は標本推定値が期望

値の附近に密に分布しているのであるから、一の任意

標本より得られた推定値を以て母数の推定値となすも

その誤差は余り大ではないであろう。しかし標準誤差

が大きい時は標本推定値の分布が広いため、一の任意

標本より得た推定値は母数より相当隔り誤差が大であ

る可能性が大きいのである。故に標準誤差の値の大小

は標本推定の精度を表すのである。若し一の母数に対

して数種の標本推定値が考えられる時は、それ等が共

に不偏推定値であるならば、標準誤差の小さい方が大

きい方よりもよい推定値であろう。又仮令或る推定値

が偏りある推定値であっても、その偏りが極めて小であつて無視し得る程度であるならば、標準誤差の大きい不偏推定値よりも、標準誤差の小さい偏りある推定値の方がよりよい推定値といえるであろう。

1) 或る母数 θ に対する数種の不偏推定値のうち誤差分散が最小なるものを最良不偏推定値 best unbiased estimate という。標本平均値は母平均の最良不偏推定値である。それは次のようにして証明される。

母平均 \bar{x} の標本推定値を $T_n = \sum_{j=1}^n a_j x_j$ とし、係数 a_j ($j = 1, 2, \dots, n$)をこの推定値が不偏であり且誤差分散が最小なるように決める事によつて、 \bar{x} の最良不偏推定値が得られる。先づ T_n が不偏であるためには次の等式が成立しなければならぬ。

$$E(T_n) = \bar{x} \quad (i)$$

しかるに

$$E(T_n) = E\left(\sum_{j=1}^n a_j x_j\right) = \sum_{j=1}^n a_j E(x_j)$$

$$= \bar{x} \sum_{j=1}^n a_j \quad ((2.29)より)$$

故にこれを(i)式と比較して

$$\sum_{j=1}^n a_j = 1 \quad (ii)$$

でなければならぬ事が判る。次に T_n の分散は

$$V(T_n) = E\{T_n - E(T_n)\}^2$$

$$= E\left\{\sum_{j=1}^n a_j x_j - \bar{x} \sum_{j=1}^n a_j\right\}^2 = E\left\{\sum_{j=1}^n a_j (x_j - \bar{x})\right\}^2$$

$$= \sum_{j=1}^n a_j^2 E(x_j - \bar{x})^2$$

$$+ \sum_{j \neq j'}^n \sum_{j'} a_j a_{j'} E\{(x_j - \bar{x})(x_{j'} - \bar{x})\}$$

しかるに $E(x_j - \bar{x})^2 = \sigma^2$ [(2.30)により]

$$E\{(x_j - \bar{x})(x_{j'} - \bar{x})\}$$

$$= \sum_{j \neq j'}^n \sum_{j'} (x_j - \bar{x})(x_{j'} - \bar{x}) \cdot \frac{1}{N} \{x_j = x_{j'}, x_{j'} = x_j\}$$

$$= \frac{1}{N(N-1)} \sum_{j \neq j'}^n \sum_{j'} (x_j - \bar{x})(x_{j'} - \bar{x}) \quad \left[\begin{array}{l} (2.32) \text{ の} \\ \text{展開参照} \end{array} \right]$$

$$= -\frac{1}{N-1}$$

∴母集団を集落に分けない場合の教内相関係数

$$\rho' = \frac{1}{\sigma^2} \left\{ \frac{1}{N(N-1)} \sum_{j \neq j'}^n \sum_{j'} (x_j - \bar{x})(x_{j'} - \bar{x}) \right\} = \frac{-1}{N-1}$$

(前講 P. 127 参照) より

$$\left[\frac{1}{N(N-1)} \sum_{j \neq j'}^n \sum_{j'} (x_j - \bar{x})(x_{j'} - \bar{x}) = -\frac{\sigma^2}{N-1} \right]$$

故に $V(T_n) = \sigma^2 \sum_{j=1}^n a_j^2 - \frac{\sigma^2}{N-1} \sum_{j \neq j'}^n \sum_{j'} a_j a_{j'}$

$$= \sigma^2 \left\{ \sum_{j=1}^n a_j^2 \cdot \frac{1}{N-1} \sum_{j \neq j'}^n \sum_{j'} a_j a_{j'} \right\}$$

$$= \frac{\sigma^2}{N-1} \left\{ N \sum_{j=1}^n a_j^2 - \left(\sum_{j=1}^n a_j \right)^2 + \sum_{j \neq j'}^n \sum_{j'} a_j a_{j'} \right\}$$

$$= \frac{\sigma^2}{N-1} \left\{ N \sum_{j=1}^n a_j^2 - \left(\sum_{j=1}^n a_j \right)^2 \right\}$$

$$\left[\left(\sum_{j=1}^n a_j \right)^2 = \sum_{j=1}^n a_j^2 + \sum_{j \neq j'}^n \sum_{j'} a_j a_{j'} \right]$$

$$= \frac{\sigma^2}{N-1} \left\{ N \sum_{j=1}^n a_j^2 - 1 \right\} \quad \text{[(ii)により]}$$

従って(ii)の条件の下に T_n の分散を最小ならしめるには $\sum_{j=1}^n a_j^2$ を最小ならしめればよい。そのような a_j はラグラン

任意標本調査法

シト乗数の法による

$$\frac{\partial}{\partial a_j} \left(\sum_{j=1}^n a_j^2 + \lambda \sum_{j=1}^n a_j \right) = 0 \quad \left(\lambda \text{ は未定乗数} \right) \quad \text{(iii)}$$

を λ に関する λ について解く事に λ について得られる。

$$2a_j + \lambda = 0 \quad \text{即ち} \quad a_j = -\frac{\lambda}{2} \quad (j=1, 2, \dots, n) \quad \text{(iv)}$$

これを(ii)に代入して

$$\sum_{j=1}^n a_j = -\frac{\lambda}{2} \cdot n = 1 \quad \therefore \lambda = -\frac{2}{n}$$

これを(iii)に代入して

$$a_j = -\frac{1}{2} \left(-\frac{2}{n} \right) = \frac{1}{n} \quad (j=1, 2, \dots, n)$$

故に

$$T_n = \sum_{j=1}^n a_j x_j = \frac{1}{n} \sum_{j=1}^n x_j = \bar{x}$$

即ち標本平均値は母平均の最良不偏推定値である。

2) この例に「比推定」がある。

今標準誤差を規定する三つの要素 ρ (比例数の推定

の場合は ρ) n 及び N の標準誤差に及ぼす影響を見る

と次の如くである。 (2.10) 式参照

(1) 標準誤差は母標準偏差 σ に正比例する。 σ が大

即ち母集団を構成する単位が異質的であり、従って個

々の単位の有する変量に大きな差異がある場合は、 σ

が小即ち母集団が比較的同質的な単位より成り、

個々の単位の変量が余り大きく異らない時に比して、

同じ大きいさの標本による推定値は誤差が大きくなりその精度が落ちるのである。

(2) 比例数の推定の場合には標準誤差は、母比例数 p

が $\sqrt{0.5}$ の範囲に於ては p の増加と共に増大し、 $\sqrt{0.5}$

に於て極大に達し、 $\sqrt{0.5}$ の範囲に於ては p の増

加と共に減少する。従つて標準誤差を以て精度の表現

となす時は、 $\sqrt{1-0.5}$ の場合が最も標本推定の精度が低

く、 p がそれより小又は大なるに従つて精度が高まる

かの如くであるが、実際は p が増大するに従つて標準

誤差は相対的に減小して行く事になるため、標本推定

の精度は p に反比例的であるという事が出来る。この

事は誤差変異係数を以て標本推定の精度を表す時に明

らかとなるのである。即ち (2.40) 式より明らかなる如く誤差

変異係数は $\sqrt{\frac{q}{p}}$ (母変異係数) に正比例し、 $\sqrt{\frac{q}{p}}$ は p

が増加する時減少するからである。(但しこの場合 p

が変動すれば q も亦変動するから) $\therefore \sqrt{\frac{q}{p}} \propto \frac{1}{\sqrt{p}}$ の

平方根に正確に反比例しない。故に比例数が大即ち

問題たる標識を有する単位が多い場合は、比例数が小

即ち問題たる標識の単位が少い場合に比して、同じ大きいさの標本による推定値は誤差が小でありその精度が高まるのである。

(3) 標準誤差は標本の大きい n の平方根に反比例す

る。故により多くの単位を抽出して構成した標本によ

る推定値の方が、少い単位の標本による推定値よりも

誤差が少く精度が高いのである。標準誤差を規定する

他の要素 σ (又は ρ) 及び N は、客観的に定まってい

る大きいさであつて如何ともし難い要素であるが、この

標本単位数 n は任意に決定し得る値であるため、これ

を増減する事によつて標準誤差の大きいさ従つて標本推

定の精度を必要な程度に管理する事が出来るのである。

しかしながら標準誤差は標本の大きいさの平方根に反比

例するのであつて、 n が 4 9 16 \dots 100 倍となるに随つて

標準誤差は $\frac{1}{2}$ $\frac{3}{4}$ \dots $\frac{1}{10}$ となるに過ぎないため、少し標

本の精度を高めるためには相当多くの標本単位数を増

加しなければならぬのである。そして標本単位数の

増加は調査に要する費用を増大せしめるため、必要以

上の精度の標本推定を可能ならしめるような大きいさの標本を構成する事は不経済であり、必要な限度に迄切下げるのが合理的であろう。かくて任意標本調査法は標本単位数の増減によつて、所期の精度の標本推定を最小の費用で獲得する事を可能ならしめるのである。

(4) 母集団の大きいさ N は正比例的に影響するがその力は小であるため、 N は標本の精度には余り関係しないのである。ただし(2.10)式に於て N が相当に大ならば

$$N-1 \approx N \text{ であるため } \sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} \sqrt{1 - \frac{n}{N}} \text{ となり、}$$

n を一定とすると有限母集団修正は N の増加と共に1に近づくがそのテムポは極めて緩慢であるからである。従つて同一精度の標本推定を得るためには、大きな母集団からも小さい母集団からも、大体同じ丈の単位数を抽出しなければならぬであつて、若し標本の大きいさを母集団の大きいさに比例させるならば、小母集団の標本推定は精度が著しく低下する事となるのである。この事から任意標本調査法は母集団が大きい程、小さい抽出率でよい精度の推定値が得られるから、効率の

高い方法である事が判るのである。

以上により明らかな如く標本推定の精度は、三つの要素のうち標本単位数 n によつて最も著しく影響されるのである。

普通標本推定の精度は標準誤差で表現されないで誤差変異係数を以て表される。例えば「或る都市の平均世帯人員の推定の精度(変異係数)は1%である」といふ、「平均世帯人員の推定の精度(標準誤差)は0.04人である」とはいわないのである。それは標準偏差は平均値を中心に測つた偏差の平均であるから、その大きいさは平均値との関連に於て考へて始めてよくその変量の分散度を表し得る事から、標本推定の精度の表現としても変異係数による方がより適切であるからである。

誤差変異係数は母変異係数に正比例し、 n 、 N よりの影響は標準誤差の場合と全く同じである。

(7) 標本の大きいさの決定

標本推定の精度は標準誤差(又は誤差変異係数)の大きいさによつて表されるため、標準誤差(又は誤差変異係数)を求める式を用いて、調査目的よりして要求される精度(これを目標精度 aimed at precision とす

う)の標本推定を実現するに必要な標本構成單位の數 n を求める事が出来る。即ち母集団の大きい N が判つて居り、母標準偏差の値を何等かの方法で推定し得るならば、調査目的より必要とされる標準誤差の値が与えられる時は、(2.10)式にそれ等の値を代入し n を未知数として解く事によって、目標精度の標本推定を実現するに必要な標本の大きい n を知る事が出来るのである。若し目標精度が誤差変異係数の値で与えられる時は、

母変異係数の値を推定し、それ等を(2.11)式に代入して n を未知数として解けばよい。普通目標精度は誤差変異

係数によって表されるため、必要標本数は(2.11)式

$$C_{\sigma^2} = \frac{c}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} \quad (2.11)$$

$$\left(\frac{c}{C_{\sigma^2}}\right)^2 = \frac{n(N-1)}{N-n}$$

$$N\left(\frac{c}{C_{\sigma^2}}\right)^2 = \left\{ \left(\frac{c}{C_{\sigma^2}}\right)^2 + (N-1) \right\} n$$

$$\therefore n = \frac{N\left(\frac{c}{C_{\sigma^2}}\right)^2}{\left(\frac{c}{C_{\sigma^2}}\right)^2 + (N-1)} = \frac{\left(\frac{c}{C_{\sigma^2}}\right)^2}{1 + \left(\frac{c}{C_{\sigma^2}}\right)^2 / N} \quad (2.14)$$

よって求められ、無限母集団又は有限母集団修正が

略々1に等しい時は

$$n = \left(\frac{c}{C_{\sigma^2}}\right)^2 \quad (2.15)$$

によって得られる。例えば世帯數26万の某市の平均家計費調査の計画に際して、精度(誤差変異係數)を5%以下に止めるには、どれ丈の單位數が必要であるかを求めよう。母変異係數は他の都市の家計調査に於ける家計費分布の変異係數0.54に鑑みて0.55と仮定したとする。母集団は極めて大きいために必要標本數は(2.45)より

$$n = \left(\frac{0.55}{0.05}\right)^2 = 121$$

故に121世帯以上を抽出しなければならぬ。

1) 母標準偏差の値は過去の調査又は類似の調査の結果より推定し得る場合が多い。特に母変異係數の値はこの可能性が大である。それは標準偏差の絶対的な値は、仮令同種の集団現象と雖も時處を異にする時は同じではないであるが、それを相対化した変異係數は、その集団現象に影響する諸条件が著しく変化しない限り、時處的に異なる同種の集団現象に於ても略々同じであると考えられるからである。しかし勿論正確な推定ではないから安全のために過大に推定するのが普通である。若し母標準偏差の推定に何等の手掛りも得られない時は、簡単な予備調査を行つて推定するのである。

尚比例數の推定の場合は、母変異係數は $C = \sqrt{\frac{q}{p}}$

$$\frac{\sum_{j=1}^n (x_j - \bar{x})^2}{n} = \frac{\sum_{j=1}^n (x_j - \bar{x})^2}{n}$$
 であるから、結局その調査によって推定せんとする母比例数 ρ の値を予測すればよいのである。この時は安全のために ρ は過小に予測すればよいである。

かくて標本調査の計画に當って目標精度の達成に必要な標本構成単位の数を数理的に求める事によって、必要な精度の標本推定を最少の調査費で獲得し、又費用が与えられて居りそれより標本の大きさが決る時は、その標本より得られる推定値の精度を予め知る事が出来るので、利用目的に照らして標本の大きさ従って調査費を増減する事によって、正確な標本推定を合理的に行う事が出来るのである。

(8) 母分散の推定

標本推定値の誤差を規定するためには、(2.10)式(及び(2.39)式)より明らかなる如く母集団の標準偏差従って分散の値を知らねばならぬ。故に次に母分散の標本推定が必要となるのである。

母分散の推定値としては標本に就ての同じ性質の簡

約表章値である標本分散を以てする事が考えられる。しかしながら標本分散 s^2 は必ずしも母分散 σ^2 の不偏推定値ではないのである。 s^2 の期望値を求めると

$$\begin{aligned}
 E(s^2) &= E \left[\frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})^2 \right] \\
 &= \frac{1}{n} E \left[\sum_{j=1}^n \{(x_j - \bar{x}) - (\bar{x} - \bar{x})\}^2 \right] \\
 &= \frac{1}{n} E \left[\sum_{j=1}^n (x_j - \bar{x})^2 - 2(\bar{x} - \bar{x}) \sum_{j=1}^n (x_j - \bar{x}) + n(\bar{x} - \bar{x})^2 \right] \\
 &= \frac{1}{n} E \left[\sum_{j=1}^n (x_j - \bar{x})^2 - n(\bar{x} - \bar{x})^2 \right] \\
 &= \frac{1}{n} \left[\sum_{j=1}^n E(x_j - \bar{x})^2 - n E(\bar{x} - \bar{x})^2 \right] \\
 &= \frac{1}{n} \left[\sum_{j=1}^n E(x_j - \bar{x})^2 - n E(\bar{x} - \bar{x})^2 \right]
 \end{aligned}$$

この式の括弧内第一項に於ける期望値は、母集団より一の単位を抽出した場合得られる値 x の標本分布の分散であるから、(2.30)式より

$$E(x_j - \bar{x})^2 = \sigma^2$$

であり、又第二項の期望値は標本平均分布の分散であるから、(2.9)式より

$$E(x_j - \bar{x})^2 = \frac{\sigma^2}{n} \frac{N-1}{N-1}$$

である。故に

$$\begin{aligned} E(s^2) &= \frac{1}{n} \left[n \sigma^2 - n \frac{\sigma^2}{n} \frac{N-n}{N-1} \right] \\ &= \frac{nN-n-N+n}{N-1} \frac{\sigma^2}{n} = \frac{N(n-1)}{N-1} \frac{\sigma^2}{n} \\ &= \frac{N}{N-1} \frac{n-1}{n} \sigma^2 \end{aligned}$$

このように s^2 は σ^2 の不偏推定値ではないのであるが、
両辺に $\frac{N-1}{N} \frac{n}{n-1}$ を乗ずる事に由り

$$E \left(\frac{N-1}{N} \frac{n}{n-1} s^2 \right) = \sigma^2 \quad (2.46)$$

となるから、 $\frac{N-1}{N} \frac{n}{n-1} s^2$ が σ^2 の不偏推定値であり
これを σ_2^2 (又は ν)と表す。即ち

$$\sigma_2^2 = \frac{N-1}{N} \frac{n}{n-1} s^2 \quad (2.47)$$

若し無限母集団又は母集団が極めて大きい時は

$$\sigma_2^2 = \frac{n}{n-1} s^2$$

であり、尚標本単位数が相当に大であり $\frac{N-1}{N}$ なる
時は

$$\sigma_2^2 = \sigma^2$$

となり、かくて始めて標本分散は母分散の不偏推定値

となるのである。

σ_2^2 の不偏推定値 σ_2^2 の標本分布の分散は、無限母集団
の場合は¹⁾

$$V \left(\frac{n}{n-1} s^2 \right) = \sigma^4 \left\{ \frac{\beta_2-1}{n-1} - \frac{\beta_2-3}{n(n-1)} \right\} \quad (2.48)$$

但し、 β_2 は母集団分布の尖峰度 $\beta_2 = \frac{1}{N} \sum_{j=1}^N (x_j - \bar{x})^4 / \sigma^4$

であり、 n が相当に大ならば $\frac{\beta_2-3}{n(n-1)} \approx 0$ となるため²⁾

$$V \left(\frac{n}{n-1} s^2 \right) \approx \sigma^4 \frac{\beta_2-1}{n-1} \quad (2.48')$$

となる。故に変異係数は

$$C_{\sigma_2^2} = \sqrt{\frac{\beta_2-1}{n-1} - \frac{\beta_2-3}{n(n-1)}} \approx \sqrt{\frac{\beta_2-1}{n-1}} \quad (2.49)$$

である。

- 1) 無限母集団でない場合の σ_2^2 の分散は極めて複雑であるので省略する。畑村、奥野「標本調査法入門」一三四—六頁に説明されているから参照されたい。

- 2) (2.48)式の証明は少し複雑となるから省略する。斎藤、浅井「標本調査の設計」三〇四—五頁に証明されている。

- 3) なんとすれば β_2 は普通の母集団分布に於ては8以下であり、 n は普通50以上であつて且分母に二次の項を含んでいるからである。

この母分散の不偏推定値を(2.9)式の σ^2 に代入する事によつて、標本平均分布の分散が推定されるのである。

$$V(\bar{x}) \approx \frac{N-n}{N-1} \frac{1}{n} \left(\frac{N-1}{N} \frac{n}{n-1} s^2 \right) \\ = \left(1 - \frac{n}{N} \right) \frac{s^2}{n-1} \quad (2.50)$$

比例数の推定の場合には母分散 $\sigma^2 = Nq$ 標本分散 $s^2 =$

p, q であるから、母分散の不偏推定値は

$$\sigma^2 = \frac{N-1}{N} \frac{n}{n-1} p'q' \quad (2.51)$$

である。従つて標本比例数分布の分散は

$$V(p) \approx \frac{N-n}{N-1} \frac{n}{n-1} \left(\frac{N-1}{N} \frac{n}{n-1} p'q' \right) \\ = \left(1 - \frac{n}{N} \right) \frac{p'q'}{n-1} \quad (2.52)$$

によつて推定されるのである。

1) ρ は不偏推定を表す記号とする。

前項に述べたように標本調査の計画に際して、母標準偏差の値の想定に基いて目標精度の達成に必要な標本の大きさが決定されるのであるが、調査の後で母分散の値を標本より推定する事によつて、果してその大きさの標本によつて目標精度が達成され得たかどうか

を確かめて置く事が必要である。このように実際の標本によつて達成された精度を達成精度 (precision attained) という。若し母標準偏差に就ての想定が誤つて居り達成精度が目標精度以下であつたならば、その調査結果は利用目的に鑑みて誤差が過大であるため正確性を欠き、又逆に達成精度が目標精度以上であつたならば、標本の大きさを減少せしめる事が出来従つて調査費の節減が可能であつたのである。故に調査立案者は計画に當つて母集団に関する智識、経験を利用して正確な母標準偏差の値を推定し、達成精度を出来る限り目標精度に一致せしめるよう努力しなければならぬ。そして標本より推定された母分散の値は、以後に於ける同種の調査の計画に際して母標準偏差想定の基本資料となり、達成精度をより以上目標精度に近附ける事を可能ならしめるのである。

(9) 標本抽出の諸方式

以上により明らかな如く任意抽出法による標本調査

は極めて正確な且合理的な調査方法であるが、それによつて実際に正確な推定値を得るためには、任意標本理論の根本的な条件である任意標本の構成、即ち N 個の母集団構成単位よりの n 個の標本構成単位の任意抽出が完全に実行されねばならないのである。任意抽出を行うためには先づ第一に、母集団を構成する N 個の単位をすべて洩れなく個々の、明確に把握し、且それより n 個の単位を任意に抽出し得るが如き状態に置く事が必要である。このような母集団構成単位を個々に記録したものを梓 frame とし、この梓の作成は任意標本調査の不可欠な前提条件である。このためには母集団単位の悉皆調査が行われねばならないのであるが、しかしそれは単に個々の単位を個別的に捉え他の単位との区別を明らかにする丈であつて、必ずしも個々の単位に就て大量観察法的個別観察を施すものではないから、悉皆統計調査に比して遙かに容易な作業である。そしてこのようにして一度或る統計集団の構成要素の梓¹⁾が作成されると、それは、以後統計集団構

成要素に変動がない限り、その統計集団を母集団とするすべての標本調査に於て利用し得るのであり、尚且往々にして他の目的より作成された記録を以てそのまま梓として用い得る場合があるのである。

1) 母集団は一方の集団性より観察した時の統計集団であるから、母集団の単位の記録は実は統計集団の単位の記録である。（拙稿「統計調査法」九六頁参照）

次に梓より n 個の単位を任意に即ち無作為に抽出する手続が実行されるのであるが、それは梓上のすべての単位に一番から N 番迄の一連番号を附け、乱数表を用いて n 個の番号を決定しその番号の単位を抽出する事によつて容易に実現されるのである。この場合 n 個の単位の一つ一つに就て乱数表を用いて抽出番号を決定する事は手続上煩雑であるため、先づ一番から $\frac{N}{n}$ （抽出間隔 sampling interval という）番迄の間の一の数を無作為に決め、それを初項とし抽出間隔を公差とする等差級数を以て抽出番号とする事によつて、 n 個の単位の無作為抽出は容易に行えるのである。これを系統的抽出法 systematic sampling といい實際上多

く用いられる方法である。枠に於ける一番から N 番迄の母集団単位の並べ方に、問題たる標識(屬性)又はそれと密接な関連を有する他の屬性に關して特定の周期的傾向があり、且それと抽出間隔とが略々一致するならば、系統的抽出法により構成された標本は特定の標識の単位を特に多く又は少く含む傾向を有し任意標本とはならないが、枠上の配列の順序に何等の傾向もなく全く偶然的であるならば、このような便法によつても抽出行為の無作為性は決して害われないであろう。

かくして任意標本が構成されるとそれに対して大量觀察の手續を施して統計を獲得し、それに統計解析的計算を加えて母数の推定値を得、又母分散を推定して信頼区間を求め標本推定の達成精度を確める事によつて標本調査は完了するのである。

以上に於ては任意標本の構成は單純に、 N 個の母集団構成単位より n 個の単位を直接抽出する事によつて行われたのであるが、任意標本の構成はこのような單純任意抽出法 simple random sampling のみならず、

層化抽出法、集落抽出法(特に地域抽出法)及び多段抽出法或は又確率比例抽出法によつても行われるのであつて、それぞれ推定の精度又は調査の費用に於て長所を有するのである。

前に述べたように標本推定の精度は母標準偏差の値、即ち母集団構成単位の變量間の差異の程度に正比例するため、この母標準偏差を小さくする事によつて標本推定の精度を高める事が出来るのであるが、それは層化抽出法と集落抽出法とによつて可能となるのである。

母集団を同質的な單位の部分集団(層 stratum)に分け、各層毎に單位を抽出して標本を構成する方法を層化抽出法 stratified sampling という。母集団を同質的な層に分つと各層に於ける單位の變量間の差異従つて標準偏差は小さくなるから、各層の値の推定の精度が高まり、故にそれを合成して母集団の値を推定する時はその精度がよくなるのである。勿論母集団の層化に際しては問題たる屬性に就て同質的な單位を集めて層を作る事は不可能であるが、それに就ての過去の

統計により或は又それと密接な関連のある他の諸屬性に従つて同質的な層に分ける事によつて、略々その目的を達する事が出来るであらう。そして仮令このような層化の基準に誤りがあつて同質化に失敗し、層内に於て問題たる標識の差異を減少せしめ得なかつたとしても、各層内での抽出が正確な枠に基く任意抽出である限り推定の不偏性を害するものではなく、只推定の偶然誤差を減少させる事に成功しなかつたのみである。

（この事は次に述べる集落抽出法に於ても妥当するのであつて、集落の構成が便宜的な基準によつてなされ母集団を、たとしてもそれは標本の精度に影響するのみである。）

次に母集団構成単位を若干個集めて集落 cluster を作り母集団を集落の集合たらしめ、それより集落を抽出して標本を構成する方法を集落抽出法 cluster sampling といい、特に母集団構成単位の地域的な集合を集落として用いる場合を地域抽出法 area sampling という。母集団を集落より成る集団に変換した場合、集

落の大きさが略々同じであり且集落相互間が可能な限り同質的であるように作るならば、（この事は母集団が異質的な単位より成つてゐる限り、出来る丈異質的な単位を集めて集落を構成する事によつてのみ可能であらう）集落の有する変量（集落を構成する単位の變量の總和）の間の差異は小くなるため母標準偏差は小となり、母集団の値の推定の精度は向上するであらう。

しかしながら實際上集落の構成は地域的な集合によつてなされる事が多いために、同質的な単位の集りであり従つて集落間異質的となり易く母標準偏差の値が大きくなるため、集落抽出法による時は推定の精度はむしろ低下するのが普通である。しかし社会的集団現象は普通広大な範囲に亘つて存在するため、抽出された標本単位が全域にばらばらに離れて存在するよりも出来る丈地域的に集つてゐる方が、大量観察法的個別観察に便利でありその費用は少なくて済むであらう。故に標本調査の實際に於ては精度が落ちるにも拘らず地域抽出法が多く用いられるのである。尚集落抽出法に於

ては単位の個別観察の費用のみならず枠の作成費の点からも費用を節減する事が出来るのである。それは単純抽出法による時は枠上に N 個の母集団構成単位を載せねばならないが、集落抽出法による時はそれよりも小数の集落を載せればよいからである。

1) 茲に於て調査単位 *unit of analysis* と抽出単位 *sampling unit* との区別が必要となるのである。調査単位は母集団を構成する単位であつて大量観察法的個別観察手続の対象たる単位であり、抽出単位は標本を構成するために母集団より抽出される単位であつて、それは抽出の便宜上定められた単位に過ぎず、調査単位それ自体であるか又は調査単位の集合(集落)である。

そして抽出された集落(地域)が尚広大であり、又はそれに含まれる調査単位数が多いためにその全部観察が困難又は不可能である時は、その集落(地域)より更に単位を抽出して標本を構成する事が必要となるのである。このように母集団より一度抽出された集落の構成単位のうちより更に単位を抽出して標本を作る方法を二段抽出法 *two-stage sampling* (又は副次抽出法 *subsampling*) といひ、最初の抽出単位たる集落を

一次抽出単位 *primary sampling unit* 二回目の抽出単位(調査単位又は集落)を二次抽出単位 *secondary sampling unit* といふ。(この場合は第一次抽出のための枠は、一次抽出単位を記載し、第二次抽出のための枠は抽出された一次抽出単位に就てのみ作成すればよいのであるから、この二次抽出単位に相当する集落又は調査単位を直接抽出する一段抽出法に比して、枠の作成の費用は著しく節減される事となるのである。) このような副次抽出を更に繰返す事によつて三段抽出法、四段抽出法等が考えられ、これ等を総称して多段抽出法 *multi-stage sampling* といふ。

尚集落抽出法に於て集落の大きさが著しく異なる時は、その抽出に際してすべての集落に等しい抽出の確率を与えて抽出するよりも、集落の大きさに略々比例した確率を与えて抽出する方が推定の精度が高まる事が数理的に証明されるのである。このように抽出単位にその大きさに比例した抽出確率を与えて抽出を行う方法を確率比例抽出法 *sampling with probability pro-*

portionate to size のこと。

以上のように諸種の標本抽出方式は、或るものは標本推定の精度を高め又或るものは調査費用を節減せしめるのである。従つて標本調査の実施に當つてこれ等諸標本抽出方式を適宜組合せる事によつて、与えられた費用と調査目的より要請される推定の精度との關係を最適ならしめるように、即ち必要な精度の標本推定を最小の費用を以て、或は又与えられた費用を以て最高の精度の推定値を獲得し得るように、標本の構造、規模を決定する事が出来るのである。これを標本設計 *sample design* としう。この標本設計のためには母集団の層化、集落化に必要な資料、各種段階に於ける費用に就ての智識、標本の大きさの決定に必要な母標準偏差の値の推定、及び諸抽出方式に應ずる不偏な推定式並にその分散式を知らねばならぬ。以下各抽出方式に於ける不偏推定式及びその分散式を求め、その抽出方式の特徴を説明しよう。