

②7 実験的研究に於ける有効な計画

序

本稿は、A. Wald 教授が講義したものを学生が編輯した "The efficient design of experimental investigation" についての Note である。

原文はタイプ刷りで、トリビアルな誤植が割合にあるため、それを補正して、note をとりました。

内容は、標本論と実験計画法が主で、特に乱化法についての詳細な解説は、新学の入門者のみならず一般数理統計家にとつても御参考になる所が多いと信じます。

最後に、昨年11月、不慮の飛行機事故で亡くなられた、Wald 先生の生前数理統計学の分野に跡された大きな功績に敬意を表し、謹んで哀悼の意を表します。

1951. 2. 8

A. Hashizume

(27) 実験的研究に於ける有効な計画

目 次

1.	はし が き	538
2.	簡 単 な 例	538
3.	一 般 的 問 題	540
4.	標 本 論	540
5.	最良線型推定値の定義	541
6.	一般的問題に於ける最良線型推定値	541
7.	マルコフの定理	543
8.	有限母集団からとられた二つの共分散	544
9.	マルコフの定理の層別標本論への応用	545
10.	m_i の最良の選び方	546
11.	單純無作為標本論と比較	548
12.	層ごとには調査費用が異なる場合の m_i の最良の 選ぶ方	549
13.	母集団 π の元素が単一の元素の代りに元素の 集りである場合の標本論	550
14.	y についての x の回帰が直線である様な管理標 識 y が存在する場合	551
15.	A の最良線型推定値	553
16.	m_i の最良の選び方	555
17.	二重標本法	556
18.	$\bar{x} = \sum_{i=1}^A p_i x_i$ の最適推定値	558
19.	m_i と N の最適な選び方	562
20.	いくつかの例	565

21.	同じ精度が要求されてゐる場合の各層の標本 数の配分の決め方	566
22.	乱化法の原理	568
23.	他の例	570
24.	乱化法の損得	573
25.	乱塊法	以下
26.	作物の平均高についての変種の効果の検定	第2巻
27.	X_{ij} の同時分布が正規であるとゆう假定のも とに於ける F の分布	第1号より
28.	乱塊法についての精密検定論	
29.	§28で定義された部分母集団に於ける統計量 F の近似分布	
30.	一般的線形假説	
31.	ラテン方格	
32.	欠測値の問題	
33.	クレゴラテン方格と超クレゴラテン方格	
34.	クレゴラテン方格に於ける標本論	
35.	超方格法 一般論	
36.	直交ラテン方格系の構成	
37.	ラテン方格計画に於ける乱化法	
38.	因子計画法	
39.	二水準に於ける二因子の系	
40.	一般的因子計画法	
41.	交格法	
42.	例	
43.	部分交格法	
44.	例	
45.	交格法と部分交格法に対する例	

②⑦ 実験的研究に於ける有効な計画

1. は し が き

統計的研究の有用性は、適当な実験計画をすることによつて増大する。最近15年間に、この様な理論は二つの方向に発展して來た。その一つは農業実験に關聯して起つたものに又他は、社会科学的、経済的実験に關聯して起つたものである。

そしてその二つの線も、理論的根底は共通してをり、その方法的技術も夫々他へ応用できるものである。

2. 簡 單 な 例

x = 高さ, y = 重さとし, x と y は二変数正規分布をしてゐると假定したとき N 件の標本から, x についての y の母集団回帰係数を推定する問題を考へる。

x_a, y_a を夫々 x, y からとられた a 番目の観測値とす。
($a = 1, \dots, N$) こので標本をとる手続きは、特性 y のみについて無作為で、 x についてはしからずとする。

即ち、調査者は、被調査の高さ x のみ着目して標本をとる。

a_0, a_1, \dots, a_k ($a_0 < a_1 < \dots < a_k$) をきめて a_{i-1}, a_i の間にある標本の数 N_i (高さについて) を任意の大きさ (但し $\sum N_i = N$) になる様にきめる事が出来るとする。

x についての y の回帰係数の最小自乗推定値の分散は $\sum (x_a - \bar{x})^2$ に逆比例する事は良く知られてゐる。

こゝで $\bar{x} = (x_1 + \dots + x_N) / N$ である。よつて統計的研究の有効性は $\sum (x_a - \bar{x})^2$ が最大になる様にきめれば、最良であることは明らかである。

他の簡単な説明は次の例で示される。一杯の茶わんの中に最初にお茶かミルクかどちらが先に加えられたかを風味することによつて見分ける事が出来る主張する婦人がいるとする。彼女の鑑別力を調べるため、或るものはお茶を或るものはミルクが夫々最初に加えられてある8つの茶わんを用意してこの婦人に鑑別させる。この際実験者は何個の茶わんが、ミルクを最初に、そして残りの何個がお茶を最初に加えてあるかを、あらかじめ婦人にしらせ、彼女に正しい分類をさせるのである。

こゝでその個数をいくつに決めたら有効な実験であるかと云ふ問題を起る。それを論じてみよう。

先づ、虚無假説(検定されるべき假説)は鑑定能力がないと云ふ事である。即ち各茶わんに対して婦人がそれを正確に分類できる確率は $\frac{1}{8}$ であると云ふ假説を立てる。

対立假説は、彼女が鑑別能力を持つ事であり、8つの茶わんを正確に分類できる確率は殆んど1である。

明らかに実験の有効性は虚無假説が正しいと云ふ前提のもとに8つの茶わんの正確に分類する確率が小さければ小さい程よい。

即ち、この場合では4つの茶わんがお茶、4つの茶わんはミルクが最初に加えられてゐるならば一番有効な実験が得られる。

即ち、(虚無假説が正しいとゆう前提のもとに)正確な分類をする確率は

$$\frac{1}{C_2^8} = \frac{4! \cdot 4!}{8!} = \frac{1}{70}$$

である。

もし3つの茶わんに最初にお茶又はミルクが加えられ、残りの6つの茶わんにミルク又はお茶を加えた様な場合には、実験の有効性の目印となる所の確率は $\frac{1}{C_2^6} = \frac{1}{28}$ で、この場合、実験によつて得られた結果が、あまり有効でなくなる。

更に8ヶの茶わんから7ヶだけをお茶又はミルクを最初に注ぎ
残りをミルク又はお茶を最初に注いだなら、例の確率は

$$1/C_7^8 = \frac{1}{8}$$

となり、実験の結果は、殆んど無価値の様に思はれる。

3 一般的問題

π を母集団とし、 Q を標本平均によつて推定しようとする、この母集団に於ける未知の母数とする。

問題は二つの観点から述べられる。1) 標本はすでに抜かれてあり、或る意味で母数 Q の最良の推定値である様な観測値の、函数 $Q^x(x_1, \dots, x_N)$ を求める事

2) 標本は引き抜き出されてなく、母集団からとられるべき観測値の数を決め、またいかなる方法で標本をとるかを定める。

我々は主として問題2を取扱い、問題1は問題2を理解するに必要な範囲で議論することにする。

§ 2 で與へられた、最初の例に於て $\sum (x_i - \bar{x})^2$ を最大ならしめる有意的選擇は無作為的選擇より良い事は良く知られてゐる。

4. 標 本 論

1) 母集団 π に於ける各元素が標本に含まれるべき機会が皆等しいときの標本抽出法を單純無作為標本抽出と云ふ。2) もしも標本の方法が、母集団 π が有限個の層に分割され、各層からあらかじめ定められた数の無作為な標本を抽出するとき、層別標本抽出法と云ふ。

3) 標本に含まれるべき元素が規範と稱する、或る方法に従つて、選ばれるとき、有意選擇法と云ふ。

(この事に関しては Ezekiel. Method of Correlation Analysis p.p. 252 ~ 255. 1930 を参照せよ)

高さに応じて選んだ § 2 に於ける例は有意選擇法の一例である。

我々は此等の三つの方法についての獲得を論じて見よう。
この爲に最良線型推定値についてのマルコフの定理を掲げる。

5. 最良線型推定値の定義

統計量 $t(x_1, \dots, x_N)$ は、もしもその期望値が未知の母集団の母数 Q に等しいならば、不偏な推定値と云ふ。

観測値 x_1, \dots, x_n の一次函数 $t = \sum \lambda_i x_i$ が Q の不偏な推定値で、また Q の他のいかなる不偏一次推定値よりも分散が小さいとき、 t を Q の最良不偏推定値であると云ふ。

例へば、もしも x_1, \dots, x_n を母集団 π からの N 回の独立な観測値とすれば、 $\bar{x} = (x_1 + \dots + x_N)/N$ は母集団平均 Q の最良線型推定値である。明らかに、 \bar{x} は Q の不偏推定値であり \bar{x} の分散は他のいかなる Q の不偏一次推定値より小さい。 σ^2 を母集団分散とすれば、 \bar{x} の分散は σ^2/N に等しい。一次結合 $t = \sum_{i=1}^N \lambda_i x_i$ の分散は明らかに $\sigma^2(\sum \lambda_i^2)$ に等しい。我々は t が Q の不偏推定値と云う条件、即ち $\sum \lambda_i = 1$ とする前提のもとに $\sigma^2(\sum \lambda_i^2)$ を最小ならしめる様に λ_i を定めよう。ラグランジュの方法を用ひるならば、容易に、その最小値は、 $\lambda_1 = \lambda_2 = \dots = \lambda_N = \frac{1}{N}$ でなければならぬ事が分るであらう。かくて \bar{x} は最小の分散を持ち、最良線型推定値である事が分る。

6. 一般問題に於ける最良線型推定値

x_1, \dots, x_N を N 回の独立な確率変数とする。

x_α の平均値、分散を夫々 $\mu_\alpha, \sigma_\alpha^2$ とする。そして

$$(1) \mu_\alpha = g_{1\alpha}\beta_1 + \dots + g_{p\alpha}\beta_p \quad (\alpha = 1, \dots, N)$$

と假定する。ここで β_1, \dots, β_p は未知で $\|g_{i\alpha}\|$ は、あらかじめ與へられた行列であるとする。

$b_i = \lambda_{i1} x_1 + \dots + \lambda_{iN} x_N$ を β_i の推定値とする。
しからば、

$$(2) \quad E(b_i) = (\sum_{\alpha} \lambda_{i\alpha} g_{1\alpha}) \beta_1 + \dots + (\sum_{\alpha} \lambda_{i\alpha} g_{p\alpha}) \beta_p$$

$$(3) \quad \sigma^2(b_i) = \sum_{\alpha} \lambda_{i\alpha}^2 \sigma_{\alpha}^2$$

推定値 b_i が不偏であるためには、次の条件が満足されなければならない。

$$(4) \quad \sum_{\alpha} \lambda_{i\alpha} g_{j\alpha} = \delta_{ij} \equiv \text{クロネッカーの}\delta\text{記号}$$

さて、条件(4)のもとに、らぐらんじゆの方法で(3)を最小にらしめるならば

$$(5) \quad \lambda_{i\alpha} \sigma_{\alpha}^2 = \sum_j k_{ij} g_{j\alpha} \quad (k_{ij}: \text{らぐらんじゆの乗数})$$

かくて、

$$\lambda_{i\alpha} = \frac{1}{\sigma_{\alpha}^2} \sum_j k_{ij} g_{j\alpha}$$

之を(4)に代入すると

$$(6) \quad \sum_{\alpha} \frac{(\sum_r k_{ir} g_{r\alpha}) g_{j\alpha}}{\sigma_{\alpha}^2} = \delta_{ij}$$

$$\sum_{\alpha} g_{r\alpha} g_{j\alpha} / \sigma_{\alpha}^2 = a_{rj} \quad \text{とおけば, (6) から}$$

$$(7) \quad \sum_r k_{ir} a_{rj} = \delta_{ij}$$

かくて

$$(8) \quad K_{ir} = C_{ir} \quad \text{但し} \quad \|C_{ir}\| = \|a_{ir}\|^{-1}$$

よつて(5)と(8)から

$$(9) \quad \lambda_{i\alpha} = \sum_r \frac{C_{ir} g_{r\alpha}}{\sigma_{\alpha}^2}$$

$$(10) \quad b_i = \sum_{\alpha} \sum_r c_{ir} \frac{g_{r\alpha} x_{\alpha}}{\sigma_{\alpha}^2}$$

が得られる。

$$I_r = \sum_{\alpha} \frac{g_{r\alpha} x_{\alpha}}{\sigma_{\alpha}^2} \quad \text{とおけば}$$

$$(11) \quad b_i = \sum_r c_{ir} I_r$$

さて (11) が最小自乗推定値と同じであることを示さう。

$\beta_1, \beta_2, \dots, \beta_p$ の最小自乗推定値 b_1^*, \dots, b_p^* は

$$\sum_{\alpha} \frac{(x_{\alpha} - \beta_1 g_{1\alpha} - \dots - \beta_p g_{p\alpha})^2}{\sigma_{\alpha}^2}$$

を最小ならしめる値である。かくて最小自乗推定値 b_1^*, \dots, b_p^* は次の方程式を満足しなければならない。

$$(12) \quad a_{i1} b_1^* + \dots + a_{ip} b_p^* = I_i \quad (i = 1, \dots, p)$$

$$\text{こゝで} \quad a_{ij} = \sum_{\alpha} \frac{g_{i\alpha} g_{j\alpha}}{\sigma_{\alpha}^2} \quad I_i = \sum_{\alpha} \frac{x_{\alpha} g_{i\alpha}}{\sigma_{\alpha}^2}$$

(12) の解は (11) 式に於ける右辺と一致する。 a_{ij} と I_i は次数 1 の $\sigma_1^2, \dots, \sigma_N^2$ について有次函数で同様に c_{ij} は次数 1 の有次函数である。従つて、 b_i は次数 0 の有次函数となる。

かくて b_i の値は、もしも、 $\sigma_1^2, \dots, \sigma_N^2$ に同じ乗数 λ^2 を掛けても不変である。

7. マルコフの定理

k_1, \dots, k_p を與へられた常数とし、 $z = k_1 \beta_1 + \dots + k_p \beta_p$ とする。

もしも b_i が β_i の最良線型推定値とすれば、

$t = k_1 b_1 + \dots + k_p b_p$ は Z の最良線型推定値である。

證 明 : $\|k_{ij}\|$ ($i, j = 1, \dots, p$) を前章に於て $g_{1\alpha}, \dots, g_{p\alpha}$ ($\alpha = 1, \dots, n$) を與へたとき、それから導かれる。或る定まった、特異でない対稱行列とする。今

$$Z_i = \sum_j k_{ij} \beta_j \quad (i = 1, \dots, p)$$

とおく。しからは

$$E X_\alpha = \mu_\alpha = g'_{1\alpha} Z_1 + \dots + g'_{p\alpha} Z_p \quad (\alpha = 1, \dots, n)$$

となる。但し $g'_{i\alpha}$ は $g_{i\alpha}$ の k_{ij} を係数とする一次線合式である。前章の結果から、 Z_1, \dots, Z_p の最良線型推定値は、最小自乗推定値 t_1, \dots, t_p に一致する。

このとき $t_i = \sum_j k_{ij} b_j$ である事が分る。

こゝで勿論 b_1, \dots, b_p は夫々 β_1, \dots, β_p の最良線型推定値である。今刻へば k_{11}, \dots, k_{1p} を夫々 k_{11}, \dots, k_{1p} に等しくする様に $(g_{1\alpha}, \dots, g_{p\alpha})$ を適当に定めれば、我々の定理は證明された事になる。

8. 有限母集団からとられた二つの共分散

M を母集団に於ける元素の總数とし、それらの元素の或る標識値を $\alpha_1, \dots, \alpha_M$ とする。

しからは母集団平均は $\mu = (\alpha_1 + \dots + \alpha_M) / M$ で、又母集団分散は $\sigma^2 = (\alpha_1^2 + \dots + \alpha_M^2 - M\mu^2) / M$ である。

X_1 と X_2 をこの母集団から れた二つの確率変数とする。しからは $E(X_i) = \mu$, $\sigma_{X_i}^2 = \sigma^2$ ($i = 1, 2$) である。最初に引出されたものが i 元素で二番目のものが j 元素 ($i \neq j$) である。確率は $1 / M(M-1)$ である。よつて

$$(13) \quad E X_1 X_2 = \frac{1}{M(M-1)} \sum_{i \neq j} \alpha_i \alpha_j$$

かくて

$$\begin{aligned}
 (13) \quad \sigma_{x_1 x_2} &= \frac{1}{M(M-1)} \sum_{i \neq j} x_i x_j - E X_1 E X_2 \\
 &= \frac{(\alpha_1 + \dots + \alpha_M)^2 - (\alpha_1^2 + \dots + \alpha_M^2)}{M(M-1)} - \mu^2 \\
 &= \frac{M^2 \mu^2 - M \sigma^2 - M \mu^2}{M(M-1)} - \mu^2 \\
 &= \frac{M \mu^2 - \sigma^2 - \mu^2}{M-1} - \mu^2 = - \frac{\sigma^2}{M-1}
 \end{aligned}$$

9. マルコフの定理の層別標本論への応用

母集団 Π は層 Π_1, \dots, Π_k に分割されてあるとする。 μ_i, σ_i^2 を夫々 Π_i の母平均及び母分散とする。そして Π_i から大きさ m_i の無作為標本を抽出する。 x_{ij} を i -層からとられた j -番目の観測値とする。 M_i を Π_i の元素の数とすると $\beta = \sum_{i=1}^k M_i \mu_i$ の最良線型推定値を求める問題を取扱はう。

パラメーター $\mu_1, \dots, \mu_k, \sigma_1, \dots, \sigma_k$ は未知で M_1, \dots, M_k は既知であるとする。線型推定値

$$b = \sum_{i=1}^k \sum_{j=1}^{m_i} \lambda_{ij} x_{ij}$$

を考へる。推定値 b はもしも

$$E(b) = \sum_{i=1}^k \sum_{j=1}^{m_i} \lambda_{ij} \mu_i = M_1 \mu_1 + \dots + M_k \mu_k$$

が、 $\mu_1, \mu_2, \dots, \mu_k$ に関して恒等的に成り立つならば不偏である。よつて

$$(16) \quad \sum_{j=1}^{m_i} \lambda_{ij} = M_i \quad (i=1, \dots, k)$$

故に我々は

$$(17) \quad \sigma_b^2 = \sum_{i=1}^k \sigma_i^2 \left(\sum_{j=1}^{m_i} \lambda_{ij} x_{ij} \right) = \sum_{i=1}^k \left\{ \sigma_i^2 \left[\sum_{j=1}^{m_i} \lambda_{ij}^2 - 2 \frac{1}{M_i-1} \sum_{j=1}^{m_i} \lambda_{ij} \lambda_{ij} \right] \right\} \\ = \sum_{i=1}^k \left\{ \frac{\sigma_i^2 \left[M_i \sum_{j=1}^{m_i} \lambda_{ij}^2 - \left(\sum_{j=1}^{m_i} \lambda_{ij} \right)^2 \right]}{M_i - 1} \right\}$$

之に (16) を使えば

$$(17') \quad \sigma_b^2 = \sum_i \sigma_i^2 \frac{M_i \sum_{j=1}^{m_i} \lambda_{ij}^2 - M_i^2}{M_i - 1}$$

が出る。各、定められた i について、 $\sum_{j=1}^{m_i} \lambda_{ij}^2$ を条件 (16) のもとに最小ならしめれば、分散 σ_b^2 は最小となる。ラグランジュの方法を用いれば、我々は容易に最小値は

$$(18) \quad \lambda_{ij}' = \frac{M_i}{m_i}$$

と置く事によつて得られる。よつて最良線型推定値は

$$(19) \quad b_i = \sum_{j=1}^k \sum_{j=1}^{m_i} \frac{M_i}{m_i} x_{ij} = \sum_{i=1}^k M_i \bar{x}_i$$

$$\text{但し} \quad \bar{x}_i = \left(\sum_{j=1}^{m_i} x_{ij} \right) / m_i$$

となる事が分る。(17') と (18) から

$$(20) \quad \sigma_b^2 = \sum_i \sigma_i^2 \frac{\frac{M_i^2}{m_i} - M_i^2}{M_i - 1} = \sum_i \sigma_i^2 M_i \frac{M_i - m_i}{m_i} \frac{M_i}{M_i - 1}$$

が得られる。

10. m_i の最良の選び方

$$M = \sum M_i, \quad m_i = \sum m_i$$

$$\sigma_i^2 = M_i \sigma_i'^2 / (M_i - 1) \quad \text{とおく, 1 からは}$$

$$\begin{aligned}
(21) \quad & \frac{M-m}{m} \sum_i M_i S_i^2 + \sum_i m_i \left[\frac{M_i S_i}{m_i} - \frac{\sum_i M_i S_i}{m} \right]^2 \\
& - \frac{M}{m} \sum_i \left\{ M_i \left[S_i - \frac{\sum_i M_i S_i}{M} \right]^2 \right\} = \frac{M-m}{m} \sum_i (M_i S_i^2) \\
& + \left\{ \left(\sum_i \frac{M_i^2 S_i^2}{m_i} \right) - \frac{(\sum_i M_i S_i)^2}{m} \right\} - \frac{M}{m} \left[\left(\sum_i M_i S_i^2 \right) - \frac{(\sum_i M_i S_i)^2}{M} \right] \\
& = \sum_i S_i^2 \left[M_i \frac{M-m_i}{m} + \frac{M_i^2}{m_i} - \frac{M_i M}{m} \right] = \sum_i S_i^2 \left[-M_i + \frac{M_i^2}{m_i} \right] \\
& = \sum_i S_i^2 \frac{M_i}{M_i-1} M_i \frac{M_i-m_i}{m_i} = \sum_i S_i^2 M_i \frac{M_i-m_i}{m_i} \frac{M_i}{M_i-1} = \sum_i S_i^2
\end{aligned}$$

が成立つ。(21)の左辺の項のみは m_i に関係するより、 S_i^2 を最小にするには、この中の項のみを $\sum m_i = m$ なる条件のもとに最小にすればよい。またこの項は

$$\sum_i \left(\frac{M_i^2 S_i^2}{m_i} \right) - \frac{(\sum M_i S_i)^2}{m}$$

に等しいから $\sum \frac{M_i^2 S_i^2}{m_i}$ を最小ならしめればよい。
 しかればその最小値は、

$$(22) \quad m_i = \frac{m M_i S_i}{\sum_i M_i S_i} \sim \frac{m M_i S_i}{\sum m_i S_i}$$

とおく事によつて得られる事がすぐ分る。

さて次に (21) の二番目の式の第二項と第三項に着目すれば

$$(23) \quad G_b^2 = \frac{M-m}{m} \sum M_i S_i^2 + \sum \left(\frac{M_i}{m_i} - \frac{M}{m} \right) M_i S_i^2$$

なる事が互いに分る。もしも $\sigma_1, \dots, \sigma_k$ が未知のとき
恐らく m_i を M_i に比例させたなら最良であらう。

もし m_i を M_i に比例させるなら (23) から勿論

$$\sigma_b^2 = \frac{M-m}{m} \sum M_i S_i^2$$

が得られる。

11. 單純無作為標本論との比較

M 個の元素からなる母集団 Π を考へる。

j 層に於ける i -元素の標識値を α_{ij} とする。 M_i を i 層の
元素の数とすれば勿論 $\sum_{i=1}^k M_i = M$ である。單純無作為標
本論の場合、即ち、各元素が同じ確率で抜きられる場合 Π の母
集団分散は

$$(24) \quad \sigma^2 = \left(\sum_{j=1}^{M_i} \sum_{i=1}^k \alpha_{ij}^2 - M\alpha^2 \right) / M$$

$$\text{但し} \quad \alpha = \left(\sum_i \sum_j \alpha_{ij} \right) / M$$

で與へられ i 層の分散は

$$(25) \quad \sigma_i^2 = \left(\sum_{j=1}^{M_i} \alpha_{ij}^2 - M_i \alpha_i^2 \right) / M_i$$

で與へられる。

(24) と (25) から

$$(26) \quad \sigma^2 = \frac{\sum_i M_i \sigma_i^2 + \sum_i M_i \alpha_i^2 - M\alpha^2}{M} = \frac{\sum_i M_i \sigma_i^2 + \sum_i M_i (\alpha_i - \alpha)^2}{M}$$

なる関係が得られる。

もしも我々は層別確率比例抽出法を採用するならば、
 $\beta = M_1 \alpha_1 + \dots + M_k \alpha_k$ の最良線型推定値は (23') によつて

異へられる分散を持つ，即ち

$$(27) \quad \sigma_b^2 = \frac{M-m}{m} \sum M_i S_i^2 \sim \frac{M-m}{m} \sum_{i=1}^k M_i \sigma_i^2 \quad (\sum m_i = m)$$

もしも我々が単純無作為比例抽出法によつて m 件の標本を抜きとるならば，即ち $k=1$ のとき $\beta = M_1 \alpha_1 + \dots + M_k \alpha_k = M \alpha$ の最良線型推定値 b^* は $b^* = M \bar{x}$ によつて異へられる。

但し \bar{x} はすべての m 件の観測値の算術平均である。

b^* の分散は (27) の右辺に於て $k=1$, $M_1 = M$, $S_1^2 = \frac{M}{M-1} \sigma^2$ とおく事によつて得られる。かくて

(26) によつて $M \sigma^2 = \sum M_i \sigma_i^2 + \sum M_i (\alpha_i - \alpha)^2$ であるから

$$(28) \quad \sigma_{b^*}^2 = \frac{M-m}{m} \frac{M^2}{M-1} \sigma^2 \sim \frac{M-m}{m} M \sigma^2 \\ = \frac{M-m}{m} \left[\sum_i M_i \sigma_i^2 + \sum_i M_i (\alpha_i - \alpha)^2 \right]$$

(27) と (28) から我々は $\sigma_{b^*}^2 - \sigma_b^2 > 0$ で，その差は $\sum_i M_i (\alpha_i - \alpha)^2$ である事を知る。

12. 層ごとに調査費用が異なる場合の m_i の最良の選び方

(26) によつて我々は

$$(29) \quad \sigma_b^2 = \sum_i \sigma_i^2 M_i \frac{M_i - m_i}{m_i} \frac{M_i}{M_i - 1}$$

である事を知った。今調査に要する全費用があらかじめ異へられてあり，例へばそれを A とする。この層で一標本あたり調査に要する費用を g_i とし，又そこからとられる標本の大きさを m_i とすれば，次の条件

$$(30) \quad \sum m_i g_i = A$$

が成立つ。かくてこの条件のもとに (29) の右辺を最小ならし

める様に，ラグランジュの方法で m_i を決定すれば

$$\frac{\partial \sigma_b^2}{\partial m_i} + \lambda g_i = - \sum_i \sigma_i^2 \frac{M_i^2}{m_i^2} \frac{M_i}{M_i - 1} + \lambda g_i = 0$$

かくて

$$m_i^2 = \frac{\sigma_i^2 M_i^3}{\lambda g_i (M_i - 1)} \quad \text{即ち } m_i \text{ は}$$

$$\frac{\sigma_i M_i^{3/2}}{\sqrt{g_i (M_i - 1)}} \sim \frac{\sigma_i M_i}{\sqrt{g_i}}$$

に比例する事が分る。

13. 母集団 Π の元素が単一な元素の代りに元素の集りである場合の標本論

人口母集団は通常群をなしてゐる。我々が標本調査をしようとする母集団は，通常各人が離れ離れに住んでゐる母集団ではない事が多い。

まとまつた各人についてある資料が記せられてゐる，カード又は帳面のあつまりである事が多い。

それらの資料は通常或る方法で一寺とめてしてある。例へば一般せんさすの資料は，各人の住所に従つてまとめてある。

即ち同じアパートに住むすべての人は一枚の用紙に書きならべてある。かゝる情勢のもとでは，實際問題として，各個人個人を無作為に引き抜く事は困難である。

かくて我々は母集団が単一な元素の集りの代りに部分集団の集りとして取扱はふ方が便利である。この場合の標本論は今迄述べて來た標本論と全く同じである。

母集団 Π が M けた群（元素）から成つてゐるとしそしてそれが k 個の層に別れてゐるとする。

M_i を i 層に於ける群の数とし, α_{ij} ($i=1, \dots, k, j=1, \dots, M_i$) を i 層 j 群に属する各人の標識 x の和であるとする。

我々は k 個の層から抽き出した無作為標本をもととして $\beta =$

$\sum_{i=1}^k \sum_{j=1}^{M_i} \alpha_{ij}$ を推定しようとする事を考える。

i 層から無作為にとつた群の数を m_i とし, i 層 j 群に属する人の標識の和を x_{ij} ($i=1, \dots, k, j=1, \dots, m_i$) とする。しかれば β の最良線型推定値は

$$b = \sum_{i=1}^k \sum_{j=1}^{m_i} \frac{M_i}{m_i} x_{ij} = \sum_{i=1}^k M_i \bar{x}_i$$

$$\text{但し } \bar{x}_i = \left(\sum_{j=1}^{m_i} x_{ij} \right) / m_i$$

σ_b^2 に対する公式も又, m_i の最良の選り方に対するものも母集団の元素が単一元素である場合と同じである。

さて我々は群の数 m_i の大きさか b の分散にどんな影響を及ぼすかについて一寸述べて見よう。

もし m_i を M_i に比例してとるならば, 分散 σ_b^2 は (23') によつて與へられる。即ち

$$\sigma_b^2 = \frac{M-m}{m} \sum M_i S_i^2 \sim \frac{M-m}{m} \sum M_i \sigma_i^2$$

である。

14. y についての x の回帰が直線である様な管理標識 y が存在する場合

x を標識値とし, その平均値は母集団 Π から推定し得るとする。次に y を管理標識と呼ばれるもう一つの標識値とし, それについては我々は y についての x の回帰線が線型であると知っておるものとする。

今 y が k の値 y_1, \dots, y_k をとり得るとする。

π を k の層 π_1, \dots, π_k に分割し、且つ π_i は y_i を含むようにする。次に d_{ij} を i 層に於ける j -元素とし、

$d_i = \left(\sum_{j=1}^{M_i} d_{ij} \right) / M_i$ とする。ここで M_i は i 層に於ける

元素の総数である。 y についての x の回帰線が線型であると云ふ事より

$$(31) \quad d_i = A + B y_i \quad (i = 1, \dots, k)$$

が成り立つ。但し A と B は或る常数である。

M_i と y_i ($i = 1, \dots, k$) は既知であると假定し、我々は

$$\alpha = \frac{1}{M} \sum_{i=1}^k \sum_{j=1}^{M_i} d_{ij} = \frac{1}{M} \sum_{i=1}^k M_i d_i$$

$$\text{但し} \quad M = \sum_{i=1}^k M_i$$

を推定する事を問題にする。

さて一般性を失ふ事無しに $\sum M_i y_i = 0$ と假定して差支ない。実際、 C を任意の常数とすると、新しい変数

$y^* = y + C$ を導入すれば、 y^* についての x の回帰線が線型であるから C を適当に選んで $\sum M_i y_i^* = 0$ とすることが出来るからである。(31) から

$$\begin{aligned} \alpha &= \frac{1}{M} \sum_i \sum_j d_{ij} = \frac{1}{M} \sum_i M_i d_i = \frac{1}{M} \sum M_i (A + B y_i) \\ &= A + B \frac{\sum M_i y_i}{M} \end{aligned}$$

$\sum M_i y_i = 0$ であるから

$$\alpha = A$$

となる。かくて我々はパラメーター A を推定しなければならぬ。

15. A の最良線型推定値

我々は i 層 ($i = 1, 2, \dots, k$) から大きさ m_i の無作為標本を抜き出し、 x_{ij} をこの標本の j 番目の値とする。

よれば A の線型推定値は

$$(32) \quad t = \sum_{i=1}^k \sum_{j=1}^{m_i} \lambda_{ij} x_{ij}$$

によって與へられる。

$$(33) \quad Et = \sum_i \sum_j \lambda_{ij} \alpha_i = \sum_i \sum_j \lambda_{ij} (A + B y_i)$$

$$= A \sum_i \sum_j \lambda_{ij} + B \sum_i \sum_j \lambda_{ij} y_i$$

となり之が不偏推定値であるためには A に一致しなければならぬ。よつて

$$(34) \quad \sum_i \sum_j \lambda_{ij} = 1$$

$$(35) \quad \sum_i \sum_j \lambda_{ij} y_i = 0$$

が成り立つ。 i 層に於ける x の母集団分散を σ_i^2 とすれば (13') 式を用い、 t の分散は

$$(36) \quad \sigma_t^2 = \sum_i \sigma_i^2 \left[\sum_{j=1}^{m_i} \lambda_{ij}^2 - \frac{2 \sum_{j \neq k} \lambda_{ij} \lambda_{ik}}{M_i - 1} \right]$$

で與へられる。條件 (34), (35) のもとに (36) を最小ならしめる様にせよ。例によつてラグランジュの方法を用ひれば

$$(37) \quad 2\lambda_{ij} - (2 \sum_{k \neq j} \lambda_{ik}) / M_i - 1 - \alpha - \beta y_i = 0$$

(α と β はラグランジュの乗数)

が得られこれは次の如く書き直せる。

$$(38) \quad \left(2 + \frac{2}{M_i - 1}\right) \lambda_{ij} - \left(2 \sum_{k=1}^{m_i} \lambda_{ik}\right) / (M_i - 1) - \alpha - \beta y_i = 0$$

よつて

$$(39) \quad \lambda_{i1} = \lambda_{i2} = \dots = \lambda_{im_i} \equiv \lambda_i \quad (i = 1, \dots, k)$$

となる。よつて

$$t = \sum \sum \lambda_{ij} x_{ij} = \sum \sum \lambda_i x_{ij} = \sum_i \lambda_i^* \bar{x}_i$$

$$\text{ただし} \quad \bar{x}_i = \left(\sum_j x_{ij}\right) / m_i \quad \lambda_i^* = m_i \lambda_i$$

又 (13') から容易に

$$\sigma_{\bar{x}_i}^2 = \sigma_i^2 \left\{ \frac{1}{m_i} - \frac{m_i(m_i - 1)}{(M_i - 1)m_i} \right\} = \sigma_i^2 \left[\frac{M_i - m_i}{m_i(M_i - 1)} \right]$$

が得られる。

$$(41) \quad W_i = \frac{m_i(M_i - 1)}{\sigma_i^2(M_i - m_i)}$$

とおく、しからば $\bar{x}_1, \dots, \bar{x}_k$ は独立で \bar{x}_i の分散は $\frac{1}{W_i}$ であるからマルコフの定理により $\bar{x}_1, \dots, \bar{x}_k$ の一次式の推定値の内 A と B の最良推定値は

$$(42) \quad \sum (\bar{x}_i - A - B y_i)^2 W_i$$

が最小ならしめる如くきめればよい。もし α と β が夫々 A と B の最良線型推定値とするなら、即ち α と β が (42) を最小ならしめる A と B の値なら、次の二つの正規方程式を満足しなければならぬ。

$$(43) \quad \begin{cases} \alpha \sum z_i^{*2} + \beta \sum y_i^* z_i^* = \sum x_i^* z_i^* \\ \alpha \sum z_i^* y_i^* + \beta \sum y_i^{*2} = \sum x_i^* y_i^* \end{cases}$$

$$\text{但し } x_i^* = \bar{x}_i \sqrt{w_i} \quad y_i^* = y_i \sqrt{w_i} \quad z_i^* = \sqrt{w_i}$$

かくて x_i^* の分散は 1 に等しいから、最小自乗法から良く知られる如く、 z_i^* の分散は C_{11} に等しい。但し

$$\begin{vmatrix} C_{11} & C_{12} \\ C_{21} & C_{22} \end{vmatrix} = \begin{vmatrix} \sum x_i^{*2} & \sum y_i^* z_i^* \\ \sum y_i^* z_i^* & \sum y_i^{*2} \end{vmatrix}^{-1}$$

よつて

$$\begin{aligned} (44) \quad \sigma_z^2 = C_{11} &= \frac{\sum y_i^{*2}}{(\sum_i z_i^{*2})(\sum_i y_i^*) - (\sum y_i^* z_i^*)^2} \\ &= \frac{\sum w_i y_i^2}{(\sum w_i)(\sum w_i y_i^2) - (\sum w_i y_i)^2} \end{aligned}$$

16. m_i の最良の選び方

我々は $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_k^2 = \sigma^2$ なる場合を考へる。 m_i は M_i に較べて非常に小さいと考へられるから、

$$\frac{M_i - 1}{(M_i - m_i)} \sim 1 \quad \text{として差支へない。}$$

よつて (41) から

$$\begin{aligned} w_i &\sim \frac{m_i}{\sigma} \quad \sigma_z^2 \sim \sigma^2 \frac{\sum m_i y_i^2}{m \sum m_i y_i^2 - (\sum m_i y_i)^2} \\ &= \sigma^2 \frac{1}{m - \frac{(\sum m_i y_i)^2}{\sum m_i y_i^2}} \end{aligned}$$

左辺は明らかに $\sum m_i y_i = 0$ のとき最小となる。

かくて、標本の大きさ m_1, \dots, m_k を $\sum m_i y_i = 0$ なる

如く定めれば σ の最小の分散が得られる。

さて、これらを導くには際して我々は $\bar{y} = (\sum M_i y_i) / M = 0$ である事を假定してゐた。もし $\bar{y} \neq 0$ なら σ の分散は容易に分る様に $\sum m_i (y_i - \bar{y}) = 0$ になるとき最小となる。

即ち、

$$\sum m_i y_i = m \bar{y} = m \frac{\sum M_i y_i}{M}$$

が満足されるならば上の等式を m で割れば、

條件

$$(46) \quad \frac{\sum m_i y_i}{m} = \frac{\sum M_i y_i}{M}$$

即ち、管理標識の標本平均についての條件が得られる。

この方法は伊太利の統計学者 C. Gini と L. Galvani によつて興へられたものである。

この方法を *proposive selection* 法と呼んでゐる。

條件 (46) は $\sigma_t = \dots = \sigma_k$ であるときにのみ σ_t^2 を最小ならしめる事に注意せよ。

この理論は又母集団の元素が単一元素の代りに群である場合にも拡張出来る。

17. 二重標本抽出法 (The method of double sampling)

問題の構成

例へば家族が食料に費す金の総高 M を推定するとかうやうに、母集団の各元素の標識 x の平均値を調べる問題を考える。

このやうな場合、それを調べるための資料を集める事は良く訓練された調査を長期に必要とし、相当金がかかるであらう。調査に要する費用があらかじめ興へられた予算で抑えられその費用の

もとで調査を実施するならば、非常に小さな標本数しかとれず、望ましい精度の推定が得られない。

もし標識 x が他の標識 y (例えば収入) に高い相関をもっているとし、 y は又 x に較べて少い費用で調査が出来るとする。このやうな場合、次の手続きで調査を行ふならば最初の標識のもとと正確な推定が得られるであらう。

先づ第二の標識 y を母集団から、十分良い精度の推定を得られる程度の大きさの標本を抜き出す。

かくて、第二の標識値に従つて、いくつかの層を作り各層に対して第一の特性に關係する資料を得られる様抜き出す。

この方法で我々は第二の標識を使はないで行ふ調査よりも、同じ調査費用でよりよい精度の推定が得られるであらう。

問題は與へられた費出のもとで最初の標本数と最初の標識の最も正確な推定を生ぜしめる部分標本をいかに決定するかである。

y の変動の範囲は既知であるとし、それを λ けの區間に分割する。例えばそれを $(y_0, y_1), (y_1, y_2), \dots, (y_{\lambda-1}, y_\lambda)$ とする。標識 y について大きさ N の標本 S_1 を抜き出す。

この標本は λ けの層に分け、その i 層は (y_{i-1}, y_i) にあるすべての観測値からなる様にする。標本 S_1 の i 層 ($i=1, \dots, \lambda$) から、我々は標識 x について、大きさ m_i の部分標本 S_{2i} をとり出す。さて π_i を $y_{i-1} < y < y_i$ なる母集団のすべての元素の集合、 π を全集合とし、 π_i を π の i 層と名付ける事にする。 p_i を π_i に属する π の元素の数との比とし、更に \bar{x} , \bar{x}_i を夫々全母集団 π , π_i に於ける x についての平均値とする。

我々は標本 S_1 , S_{2i} をもとにして $\bar{x} = \sum_{i=1}^{\lambda} p_i \bar{x}_i$ を推定しようとする事を試みる。標本 S_1 から比 p_1, \dots, p_λ を推定する事が出来、又標本 S_{2i} から \bar{x}_i を推定する事が出来る。

$m_0 = \sum_{i=1}^{\lambda} m_i$ とし、 A , B を夫々標識 x , y についての

一元素についての調査費用とすれば全費用は

$$(47) \quad A m_0 + B N = C$$

で與へられる。今 C は固定されてゐるとし條件 (47) のもとに、 m_1, \dots, m_s ; N のもつともよい値を探す問題を取扱ふのがこの目的である。

18. $\bar{x} = \sum_{i=1}^s p_i \bar{x}_i$ の最適推定値

n_i を i 層に属する S_i の元素の数とすれば p_i の最良推定値は勿論 n_i/N である。

x_{ij} を標本 S_{2i} に於ける j 元素の x の値とする。

我々は \bar{x} の推定値が

$$(48) \quad F_1 = \sum_{i=1}^s \sum_{j=1}^s \sum_{k=1}^{m_i} \lambda_{ijk} r_i x_{jk}$$

なる形をしていると予め制限して置く。こゝで λ_{ijk} は常数である。推定値 (48) が次の二つの条件を満足するとき最良であると云ふ。

$$(i) \quad E(F_1) = \bar{x}$$

(ii) F_1 の分散が性質 (i) をもつ他のいかなる (48) の形の推定値のそれより小さい。

かくて我々は条件 (i) (ii) が満たされる様に、係数 λ_{ijk} を決めよう。 $E(F_1)$ を計算するために母集団に於ける各層 π_1, \dots, π_s の元素の総数は標本に於ける各層のそれに較べて非常に大きいと假定する。従つて、標本の—こ—このとり方は互ひに独立であると假定してしまふ。

S_{2i} は標本 S_i の i 層からとられ π_i から直接ではないけれども、変数 r_i と x_{jk} は独立である。

これは次の様にして知る事が出来る。

全母集団 Π から無作為標本 S_i を抜く代りに各層 π_i から大きさ n_i の無作為標本を抜く。たゞ n_1, \dots, n_d は與へられる数で $\sum n_i = N$ であると考えられる。^{*}

この標本は x の値に関係なく抜かれたものであるから x_{jk} の分布は、数 n_1, \dots, n_d に無関係である。

かくて

^{*} 註. 之は誤りである。 n_i は確率変数であるから $n_i = 0$ なる値をとり得る。よつて、後で m_i を決める時 $n_i \geq m_i$ でなければならぬから、 m_i を決定出来なくなる場合がある。

もし、この様な事が起る場合、標本採取りをやりなせば偏倚な推定値となる。

統計数理研究所輯報 No. 2 林知己夫、石田正次、白河市言語調査に於けるサムプリング調査計画を参照されたい。

固定された r_1, \dots, r_d についての x_{jk} の条件附確率は r_1, \dots, r_d に関係しない。その結果、 r と x_{jk} は独立に分布する。従つて

$$\begin{aligned} E(F_1) &= \sum_{i=1}^d \sum_{j=1}^d \sum_{k=1}^{m_i} \lambda_{ijk} E(r_i) E(x_{jk}) \\ &= \sum \sum \sum \lambda_{ijk} p_i x_j \end{aligned}$$

故に條件 (i) によつて

$$\sum_{i=1}^d \sum_{j=1}^d \sum_{k=1}^{m_i} \lambda_{ijk} p_i x_j = \bar{x} = p_1 x_1 + \dots + p_d x_d$$

かくて

$$(49) \quad \begin{cases} \sum_{k=1}^{m_i} \lambda_{ijk} = 0 & i \neq j \\ \sum_{k=1}^{m_i} \lambda_{iik} = \frac{1}{m_i} \end{cases}$$

が得られる。

さて次に F_i の分散 V_i を求めよう。先づ r_1, \dots, r_n が固定された常数であると云ふ假定のもとに F_i の分散 V_i^* を求めてみる。 σ_i^2 を π_i における x の分散とすると

$$(50) \quad V_i^* = \sum \sum \sum (\lambda_{ijk})^2 r_i^2 \sigma_j^2$$

が得られる。任意の確率変数 x に対し r_1, \dots, r_n が固定された時の x の条件附期望値を $E(x/r_1, \dots, r_n)$ とすると明らかに次式が成立つ

$$(51) \quad E(F_i^2/r_1, \dots, r_n) = V_i^* + \{E(F_i/r_1, \dots, r_n)\}^2$$

$$= \sum \sum \sum \lambda_{ijk}^2 r_i^2 \sigma_j^2 + \left\{ \sum \sum \sum \lambda_{ijk} r_i x_j \right\}^2$$

(49) から

$$\sum \sum \sum \lambda_{ijk} r_i x_j = \sum_{i=1}^n r_i x_i$$

である事が分るから

$$(52) \quad E(F_i^2/r_1, \dots, r_n) = \sum \sum \sum \lambda_{ijk}^2 r_i^2 \sigma_j^2 + \left(\sum_{i=1}^n r_i x_i \right)^2$$

F_i^2 の条件の附かない期望値 $E(F_i^2)$ は r_1, \dots, r_n を確率変数であるとしたときの (52) の右辺の期望値に等しい。

$$E(r_i r_h) = p_i p_h \left(1 - \frac{1}{N} \right) \quad (i \neq h)$$

$$E(V_i^2) = p_i^2 + p_i(1-p_i)/N$$

であるから

$$(53) \quad E(F_i^2) = \sum \sum \sum \lambda_{ijk}^2 \left[p_i^2 + p_i(1-p_i)/N \right] \sigma_j^2 \\ + \sum_i \left[p_i^2 + p_i(1-p_i)/N \right] x_i^2 + \sum_{i \neq k} p_i p_k x_i x_k \left(1 - \frac{1}{N} \right)$$

よつて

$$(54) \quad V_i = E(F_i^2) - (p_i x_i + \dots + p_n x_n)^2 \\ = \sum \sum \sum \lambda_{ijk}^2 \left[p_i^2 + p_i(1-p_i)/N \right] \sigma_j^2 \\ + \frac{1}{N} \sum_i p_i(1-p_i) x_i^2 - \frac{1}{N} \sum_{i \neq k} p_i p_k x_i x_k$$

(54) から条件 (49) のもとに λ_{ijk} についての V の最小値は、もしも

$$(55) \quad \begin{cases} \lambda_{ijk} = 0 & i \neq j \\ \lambda_{jjk} = \frac{1}{m_j} \end{cases}$$

なるとき成立つ事分かる。これらの値を (54) に代入すれば

$$(56) \quad V_i = \sum_{i=1}^A \left\{ \left[p_i^2 + \frac{p_i(1-p_i)}{N} \right] \frac{\sigma_i^2}{m_i} + \frac{p_i(1-p_i)}{N} x_i \right\} \\ - \frac{1}{N^2} \sum_{i=1}^{A-1} \sum_{j=i+1}^A p_i p_j x_i x_j$$

が得られる。(48) と (55) から \bar{x} の最良推定値は

$$(57) \quad F_i = \sum_{i=1}^A r_i x_i$$

但し
$$x_i = \frac{\sum_{j=1}^{m_i} x_{ij}}{m_i}$$

によつて與へられる。

19. m_i と N に対する最適な與へ方

任意の変数の組 (a_1, \dots, a_s) に対して次の恒等式が成立つ。

$$\begin{aligned}
 (58) \quad & \sum_{i=1}^s m_i \left(\frac{a_i}{m_i} - \frac{\sum_i a_i}{\sum_i m_i} \right)^2 \\
 & \equiv \sum \frac{a_i^2}{m_i} - \left(\sum_i 2a_i \right) \frac{\sum a_i}{\sum m_i} + \frac{(\sum a_i)^2}{\sum m_i} \\
 & \equiv \sum \frac{a_i^2}{m_i} - \frac{(\sum a_i)^2}{\sum m_i} = \sum \frac{a_i^2}{m_i} - \frac{(\sum a_i)^2}{m_0}
 \end{aligned}$$

$a_i = \sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}}$ とおけば (58) から

$$\begin{aligned}
 (59) \quad & \sum_i \left[p_i^2 + p_i(1-p_i)N^{-1} \right] \frac{\sigma_i^2}{m_i} \\
 & = \frac{\left[\sum_i \sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}} \right]^2}{m_0} \\
 & + \sum m_i \left(\frac{\sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}}}{m_i} - \frac{\sum_i \sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}}}{m_0} \right)^2
 \end{aligned}$$

更に

$$\begin{aligned}
 (60) \quad & \sum p_i(1-p_i)x_i^2 - 2 \sum_{i=1}^{s-1} \sum_{j=i+1}^s p_i p_j x_i x_j = \sum_i p_i x_i^2 - (p_1 x_1 + \dots + p_s x_s)^2 \\
 & = \sum p_i x_i^2 - \bar{x}^2 = \sum p_i (x_i - \bar{x})^2
 \end{aligned}$$

(56), (59), (60) から

$$\begin{aligned}
 (61) \quad V_1 = & \frac{(\sum \sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}})^2}{m_0} + \sum_i m_i \left(\frac{\sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}}}{m_i} \right. \\
 & \left. - \frac{\sum_i \sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}}}{m_0} \right)^2 + \frac{1}{N} \sum_i p_i (x_i - \bar{x})^2
 \end{aligned}$$

この式の右辺の第一項と第三項は m_i に無関係で m_0 と N に関係する。よつて m_i ($i = 1, \dots, J$) は中央項が 0 になる様に選べば、即ち

$$(62) \quad m_i = \frac{m_0 \sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}}}{\sum \sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}}}$$

とおく。これから (61) は

$$(63) \quad V_1' = \frac{(\sum \sigma_i \sqrt{p_i^2 + p_i(1-p_i)N^{-1}})^2}{m_0} + \frac{1}{N} \sum p_i (x_i - \bar{x})^2$$

に簡約される。更に $p_i(1-p_i)N^{-1}$ を無視すれば

$$(64) \quad V_1' \sim V_1'' = \frac{(\sum \sigma_i p_i)^2}{m_0} + \frac{1}{N} \sum p_i (x_i - \bar{x})^2$$

我々は条件

$$A m_0 + B N = C$$

のもとに (64) の右辺を最小なる如く定めれば最適な選び方となる。

$$(\sum p_i \sigma_i)^2 = a^2, \quad \sum p_i (x_i - \bar{x})^2 = b^2$$

とおけば

$$(65) \quad \frac{a^2}{m_0} + \frac{b^2}{N}$$

を条件 $A m_0 + B N = C$ のもとに最小ならしめればよい。

ラグランジュの方法を用いて

$$-\frac{a^2}{m_0^2} = -\lambda A, \quad -\frac{b^2}{N^2} = \lambda B$$

(l = ラグランジュの乗数)

である事を知る。

よつて m_0, N は夫々 $\frac{a}{\sqrt{A}}, \frac{b}{\sqrt{B}}$ に比例せればよい

事が分る。 即ち

$$m_0 = K \frac{a}{\sqrt{A}}, \quad N = K \frac{b}{\sqrt{B}}$$

比例項 K の値は

$$(68) \quad K (a\sqrt{A} + b\sqrt{B}) = C$$

から求まる。(67) (68) から

$$(69) \quad m_0 = (a/\sqrt{A} + b\sqrt{AB}) : N = (b/(\sqrt{AB} + \sqrt{B}))$$

が出る。

上の結果から知る通り、我々は m_0, N , 又 m_i の最適な値を求めるために、母数, p_i, σ_i, x_i が既知であるとした。
しかしそれらの値は、初等的不等式から推定しうるものである。

p_i, σ_i, x_i の第一次近似値は得られる。それらを (69) (62) 式に代入すれば m_0, N, m_i の近似値が得られる。

二重標本調査法を用ふべきか否かを定める

前に、我々は、それが直接的な単純無作為標本調査法よりよい結果を興へるであらうか。どうかについて研究すべきである。

同じ費用 C のもとに、大きさ $M = C/A$ の単純無作為標本 S_0 を採用し、母集団平均 \bar{X} の線型推定値を求めるならば、其の最良推定値は標本平均 \bar{x} で、分散 V_0 は

$$(70) \quad V_0 = \frac{1}{M} \left[\sum p_i \sigma_i^2 + \sum p_i (x_i - \bar{x})^2 \right] \quad \text{但し } M = \frac{C}{A}$$

で興へられる。式 (70) は単一観測の分散が式 (26) で興へら

れると云ふ等から従ふ。かくて二重標本抽出法を用ゐるかどう
かを決定するためには、我々は p_i , σ_i^2 , x_i に対して、既知の知
識又は基礎的不等式から得られる基礎的値を代入して (70), (69)
(64) 式で夫々與へられる値 V_0 , m_0 , N , V'' を計算してみ
る。そして V_1'' が V_0 より小さいか大きいかによつて二重標本
抽出法が單一單純無作為標本抽出法を用ゐるより有利であるか、
ないかを定めるべきである。

20. 或る例

$$J=3, \quad p_1 = \frac{1}{4}, \quad p_2 = \frac{2}{4}, \quad x_1 = 1, \quad x_2 = 3, \quad X = 6$$

$$\sigma_1 = 1, \quad \sigma_2 = 2, \quad \sigma_3 = 4, \quad A = 4, \quad B = 1, \quad C = 500$$

とすれば

$$a = \sum p_i \sigma_i^2 = 2.25$$

$$\bar{x} = 3.25$$

$$b^2 = \sum p_i (x_i - \bar{x})^2 = 3.1875 = (1.7854)^2$$

を得る。(61) から最適値

$$m_0 = 89 \quad N = 142 \quad (\text{最も近い整数値})$$

$$\text{更に (62) 式を用ひて } m_1 = 10 \quad m_2 = 39 \quad m_3 = 40$$

が得られる。分散 V_1 は (63) から

$$(71) \quad V_1 = .079555$$

この値が、 m_i を (62) に従つてきめたい値から得られる分散と
比較してみるのは興味がある。例へば $m_1 = 29$ $m_2 = m_3 = 30$
とおけば

$$V_1 = .0919$$

を得る。かくて (71) で與へられた値よりも、15 % も多くなり精度に於て、考へなければならぬ、又不必要な損失を招く (70) から又

$$(72) \quad V_0 = .0755$$

を得る。かくてこの場合 $V_1 > V_0$ で單純無作為標本抽出法を用いた方がよりよい精度を得る事が分る。

この結果は変数 x についての層間の違いが層内に於ける x の変異に比べて小さいという事と、 x, y について資料を得るための費用の差があまり大きくないという事実によるものである。

この事を説明するために、次の例を考へよう。

例 II. p_i, σ_i, x_i は、例 I. に於けると同じとする。
 $A = 40, B = 1, C = 5000$ とすれば、 C/A は例 I と同じ値をとるから V_0 も例 I と同じになる。しかしこの場合

$$V_1 = .05147$$

となり、二重標本抽出法を用いた方が大きな利益を得る。

例 III. p_i, σ_i, A, B, C は、例 I. と同じとする。
 $x_1 = 1, x_2 = 6, x_3 = 11$ とする。層間の変差は例 I より大きくなつてゐる。必要な計算を実行すると

$$V_0 = .15 \quad V_1 = .129$$

となり、この場合も二重標本抽出法の方が直接的な單純無作為標本抽出法より 15 % も精度が良くなつてゐる。

21. 同じ精度が要求される場合の各層の標本数の配分の決め方

をこの層、 π_1, \dots, π_k に層別された母集団 π を考へる。
 x を或る標識とし、 α_{ij} を i 層に於ける j 元素の値とす

る。

M_i を π_i に於ける元素の総数 $M = \sum_{i=1}^k M_i$ とし、

$$d_i = \left(\sum_{j=1}^{M_i} d_{ij} \right) / M_i$$

とおく前の講義に於て我々はパラメーター

$$B = \sum_{i=1}^k \sum_{j=1}^{M_i} d_{ij} = \sum_{i=1}^k M_i d_i$$

を推定する問題を考へた。このために k この層の間の標本数の最良の配分は (22) で與へられた。

しかしながら、 B を推定するための目的でなく層 π_1, \dots, π_k の平均 $\alpha_1, \dots, \alpha_k$ そのものを調べ、それらを互ひに比較する事が目的である場合もたまに起る。

このやうな場合には於て我々は $\alpha_1, \dots, \alpha_k$ が皆同じ精度で推定される事が望ましい。 m_i を i 層からとられた標本数 \bar{x}_i をその標本平均とする。

又 σ_i^2 を i 層の母集団分散とすれば \bar{x}_i の分散は

$$\sigma_{\bar{x}_i}^2 = \frac{\sigma_i^2 (M_i - m_i)}{m_i (M_i - 1)}$$

で與へられる。もし標本の大きが定まつてゐるならば、例へばそれを m とするとき m_1, \dots, m_k は次の方程式を満足しなければならぬ。

$$m_1 + \dots + m_k = m$$

(73)

$$\frac{\sigma_1^2 (M_1 - m_1)}{m_1 (M_1 - 1)} = \dots = \frac{\sigma_k^2 (M_k - m_k)}{m_k (M_k - 1)}$$

もし M_i が m_i に較べて非常に大きいならば $\frac{M_i - m_i}{M_i - 1}$ は、

1 に近似するから、この場合上の二つの方程式は

$$m_1 + \dots + m_k = m, \quad \frac{m_1}{\sigma_1^2} = \dots = \frac{m_k}{\sigma_k^2}$$

即ち、標本の大きさ m_1, \dots, m_k は分散 $\sigma_1^2, \dots, \sigma_k^2$ に比例してとるべきである。(73)式の取扱ひに関しては *Stock and Frankel Annals of Math. Statistics* p. 238. Sep. を参照せよ。

22. 乱化法の原理

統計的研究計画に於ける重要な道具の一つとして、所謂乱化法と呼ばれる方法がある。それを簡単な例で説明してみよう。

ミルクが注がれてあるお茶を、ミルクがお茶かどちらが最初に加之られたかを風味する事によつて鑑別出来ると主張する一人の婦人がいるとする。そこで、ミルクが最初に注がれた茶わん4けと、お茶が最初に加之られた茶わん4け、合計8けの茶わんを用意せよ。

虚無假説として、この婦人は鑑別能力がないと云ふ假説を立てる。即ち、8けの茶わんを4けずつの二つの群に分けるいかなる分類の仕方でも、同様な可能性をもつとする。このやうな分類の仕方は $\frac{8!}{4!4!} = 70$ 通りであるから、虚無假説のもとで、正しい分類が出来ゐる確率は $\frac{1}{70}$ に等しい。虚無假説が真であるときすべての分類の仕方の確率は各々相等しい事を保証するためには、婦人の判断に影響を及ぼすやうなすべての他の事柄に関して、同じ様な条件をつけないはならない。

例へば、ミルクを最初に注いだ茶わんに砂糖を加へ、他の茶わんにそれを加へないならば、それらを風味する事によつて婦人の判断力に影響を及ぼす明りやうな違いがある。

その他結果を損うやうな多くの起り得る誤差がある。

例へば、ミルクの量を茶わんごとにいろいろ変へる等。

我々が検定しようとする事柄——即ちミルクとお茶とどちらが先に加えられてゐるか——以外の事で8杯の茶わんについて完全に同じやうな状態に、実験を計画する事は不可能である。

しかし、それらの有意な変異は乱化法で、かなり広範囲まで消去する事が出来る。それらの有意因子をあらかじめ決めてしまつてから、8杯の茶わんから、無作為に4杯を決めてしまう。

しからば、虚無假説が真であるという前提のもとに、有意因子の存在の如何に係はらず婦人が正しい分類をする確率はやはり、 $1/70$ である。

これは次の様にして知る事が出来る。

8杯の茶わんを4杯ずつの二つの群に分類する仕方の数は70通りある。それを C_1, C_2, \dots, C_{70} と記してみる。

検定すべき事柄については婦人は鑑別力はないが、しかし8杯の茶わんの分類についての婦人の判定に影響を及ぼす、例へば、茶わんごとに砂糖の分量を変へるとかう様な或る有意因子がきまつてゐるとする。

彼女が分類 C_i を決定する確率を p_i とすれば、 p_i は有意因子が存在するから一般に $1/70$ と異なるであらう。

実験者は有意因子をどの茶わんに施すかを夫々きめて、それからその8杯の茶わんから4杯を無作為に4杯選り、それに最初にお茶を注ぎ、残りに最初にミルクを注ぐ。

実験者は70通りの分類の仕方 C_1, \dots, C_{70} から一つを無作為に選擇する事が云へた。

虚無假説が正しいと云ふ前提のもとづけは、婦人によつてなされた分類は実験者によつて選ばれた分類と独立である。よつて実験者が C_i を選り又婦人がこれと同じ分類 C_i を決める確率は積 $p_i \cdot \frac{1}{70}$ に等しい。よつて婦人が正しい分類をなす確率は婦人の分類と実験者のそれが一致する場合でそれは、

$$\sum_{i=1}^{70} p_i \frac{1}{70} = \frac{1}{70}$$

に等しい。かくて彼女が正しい分類をする確率は、もしもすべての有意因子がきめられてしまった後、実験者による4つの茶めんの無作為選擇（無作為にどの茶めんにお茶又はミルクを最初につぐかをきめる事）をするならば有意因子が存在しない場合と同じになる。

乱化法の重要性は、乱化法が適用される事によつて、有意因子の存在によつて起される所の検定手續に於けるいかなる偏倚も消去されると云ふ事實による。

23. 他 の 例

我々は農作物のいろいろの麦種の作高の平均値が取扱ひ、 u と v によつて同じであるかどうかとゆう假説を検定したい。

このために我々は15対の実験用プロットを用意する。

そして各一对のプロットに取扱ひ、 u と v を施す事にする。

u_{α} 、 v_{α} を α 番目のプロットに夫々取扱ひ u 、 v による作高とする。 $P_{\alpha 1}$ 、 $P_{\alpha 2}$ を夫々 α 番目の左側、右側プロットとする。 $y_{\alpha i}$ ($i=1, 2$) をプロット $P_{\alpha i}$ に於ける取扱ひが施されない場合の作高の平均値とする。

$\mu + \delta_{\alpha i}$ 、 $\nu + \beta_{\alpha i}$ を夫々取扱ひ u 、 v が施されたときのプロット $P_{\alpha i}$ に於ける作物平均高とする。

さて30枚の取扱ひ、 u_1, \dots, u_{15} 、 v_1, \dots, v_{15} は独立に分布しているとする。作高は一般に土壤肥沃度の差によつて異なるであらう。もしもプロットの対を（例へば硬質を投げる等によつて）無作為に決めるならば、次の式が成り立つと假定してみる。

1	u_1	v_1
2	u_2	v_2
3	u_3	v_3
4	u_4	v_4
5	u_5	v_5
6	u_6	v_6
7	u_7	v_7
8	u_8	v_8
9	u_9	v_9
10	u_{10}	v_{10}
11	u_{11}	v_{11}
12	u_{12}	v_{12}
13	u_{13}	v_{13}
14	u_{14}	v_{14}
15	u_{15}	v_{15}

$$(74) \quad \begin{cases} u_\alpha = \mu + \varepsilon_\alpha + \eta_\alpha \\ v_\alpha = \nu + \varepsilon'_\alpha + \eta'_\alpha \end{cases}$$

こゝで $\varepsilon_1, \dots, \varepsilon_{15}, \varepsilon'_1, \dots, \varepsilon'_{15}$ は平均 0 をもつて独立に分布する確率変数で、 η_α は γ_{21}, γ_{22} のいずれかの値を確率でとる。
又

$$\eta'_\alpha = \gamma_{\alpha 1} + \gamma_{\alpha 2} - \eta_\alpha \quad \text{である。}$$

よつて

(75)

$$u_\alpha - v_\alpha = (\mu - \nu) + (\varepsilon_\alpha - \varepsilon'_\alpha) + (2\eta_\alpha - \gamma_{\alpha 1} - \gamma_{\alpha 2})$$

かくて

$$E(u_\alpha - v_\alpha)$$

$$= E(\mu - \nu) + E(\varepsilon_\alpha) - E(\varepsilon'_\alpha) + E(2\eta_\alpha - \gamma_{\alpha 1} - \gamma_{\alpha 2})$$

$$= \mu - \nu$$

よつて、虚無假説が正しいならば、即ち

$$\mu = \nu$$

ならば、 $u_1 - v_1, \dots, v_{15} - v_{15}$ は平均 0 をもつて独立に分布する。もしも $(u_\alpha - v_\alpha)$ ($\alpha = 1, \dots, 15$) が、同じ分散をもつて正規分布に従ふならば、良く知られた分布

$$t = \frac{\sqrt{15} \bar{z}}{s}$$

$$\text{但し} \quad \bar{z} = (z_1 + \dots + z_{15})/15 \quad z_\alpha = u_\alpha - v_\alpha$$

$$s^2 = \frac{\sum_{\alpha=1}^{15} (Z_{\alpha} - \bar{Z})^2}{14}$$

をなす。オ検定は、もとの分布が正規でないときも、その標本数があまり小さくなければ、近似的に之を用いても差支へない。

もしもオ検定の適用性がうたがはしい時には R. A. Fisher によつて導かれた所の次の正密検定を用ひる事が出来る。

確率変数、 $\varepsilon_1, \dots, \varepsilon_{15}$; $\varepsilon'_1, \dots, \varepsilon'_{15}$ については、その平均が 0 で独立にしかも同じ分布法則に従つてゐる事以外に何も知られてゐないとする。しからば $\varepsilon_{\alpha} - \varepsilon'_{\alpha}$ の分布は、縦軸に關して対稱で、又 $(2\eta_{\alpha} - \gamma_{\alpha_1} - \gamma_{\alpha_2})$ の分布も縦軸に關して対稱で且つ η_{α} は ε_{α} と ε'_{α} と独立であるから (75) から、 $u_{\alpha} - v_{\alpha}$ の分布はもし虚無假説が眞である、即ち $\mu - \nu = 0$ ならば、縦軸に關して対稱である。

我々は $|u_{\alpha} - v_{\alpha}|$ があるきまつた値、例えばそれを V_{α} を持つ所の部分母集団を考へよう。

$u_{\alpha} - v_{\alpha}$ の分布の対稱性から與へられた部分母集団に於て、 $u_{\alpha} - v_{\alpha}$ が V_{α} に等しい確率も又 $-V_{\alpha}$ に等しい確率も共に $\frac{1}{2}$ である。

次に $(r_1, r_1, \dots, r_{15}, r_{15})$ (但し $r_1, \dots, r_{15} = \pm 1$) なる 2^{15} 組の数列を考へよう。しからば與えられた部分母集団に於て 2^{15} の数列の各々は皆等しい確率を持つから、かくて又、それに対応する $\bar{Z} = (\sum_{\alpha=1}^{15} r_{\alpha} \gamma_{\alpha}) / 15$ の値は同じ確率を持つて起る。 \bar{Z} のそれらの 2^{15} の値を大きい順に並べ、この並べた両端に於ける棄却域を決める。即ち標本から計算された

$$\sum_{\alpha=1}^{15} (u_{\alpha} - v_{\alpha}) / 15$$

が、この並べられた \bar{Z} -数列の或る片側に落ちれば、 $\mu - \nu = 0$ とゆう假説を棄却する事にする。

いて棄却域に含まれる \bar{x} 数列の \bar{x} の数を a とすると、もし虚無假説が真であるとき、之を誤つて棄却する確率は $a/2^{15}$ に等しい。もし検定と較べて、この検定方法の利失は、虚無假説が真であるとき、これを棄却する確率が、 ϵ_{α} の未知の分布の型に関係しない事である。

24. 乱化法の利失と欠失

乱化法の利点は、それが有意因子の存在の有無に係はらず不偏な検定が出来るところにある。

例えば、§ 23 で挙げた例では、有意因子はプロットの相違による土壌肥沃度である。即ち α と β の函数である所の $\gamma_{\alpha\beta}$ がそれである。

$$\gamma_{\alpha_1} - \gamma_{\alpha_2} = \delta \quad (\alpha = 1, \dots, 15)$$

δ を或る正の常数とすれば、取扱ひ、 u 、 v を夫々プロットの左側、右側に施したとき、虚無假説、即ち $\mu = \nu$ が真であつたと、差 $\sum u_{\alpha}/15 - \sum v_{\alpha}/15$ に有意を見出すであらう。

この場合、虚無假説が正しいと云ふ前提のもとでも $u_{\alpha} - v_{\alpha}$ の期望値が 0 でなく、 δ に等しいから検定は相當な偏倚をもたらす。しかしながらもし実験を § 23 で述べた方法で乱化するならば $(u_{\alpha} - v_{\alpha})$ の期望値は γ_{α} のいかに係はらず常に $\mu - \nu$ に等しい。(もしも虚無假説が正しいならば、それは 0 である。) かくて、もし $\gamma_{\alpha\beta}$ が未知であるとき、乱化法は検定を不偏にする利失を持ち、他のいかなる系統的並べ方も偏倚検定をもたらす事になる。

しかしながら乱化法は次に述べる或る欠失をも持つてゐる。それは統計的検定のもとゝなる分散の増大によつて検定の感度を減小せしめる事である。

この事をもつと詳しく説明しよう。

$\gamma_{\alpha_1} - \gamma_{\alpha_2} = \delta > 0$ である場合を考える。

しからは $y_{\alpha_1} + y_{\alpha_2} - 2\eta_{\alpha}$ は $+\delta$ か $-\delta$ かいづれかを夫々、確率 $1/2$ でとる。 ε_{α} , ε'_{α} の分散は皆 σ^2 に等しいとする。 しからは (75) から $(u_{\alpha} - v_{\alpha})$ の分散は $2\sigma^2 + \delta^2$ に等しい事が分る。 よつて $\sum (u_{\alpha} - v_{\alpha})/N$ の分散は $(2\sigma^2 + \delta^2)/N$ に等しい。 こゝで N は、我々が実験に対して用いられるプロットの対の数とする。 さて我々は次の無作為な並べ方と、系統的な並べ方とを比較してみよう。

取扱ひ、 u はプロット $P_{1,1}, \dots, P_{\frac{N}{2},1}, P_{\frac{N}{2}+1,2}, \dots, P_{N,2}$ に施し、 v は残りのすべてのプロットに施すとする。 (N は偶数であるとしておく) しからは $(\sum u_{\alpha} - \sum v_{\alpha})/N$ の期望値は $\mu - \nu$ に等しく (もし虚無假説が正しければ 0 に等しい) 又、 $(\sum u_{\alpha} - \sum v_{\alpha})/N$ の分散は $2\sigma^2/N$ である。 又 σ^2 は

$$\sigma^2 = \frac{\sum_{\alpha=1}^{N/2} (z_{\alpha} - \bar{z}_1)^2 + \sum_{\alpha=\frac{N}{2}+1}^N (z_{\alpha} - \bar{z}_2)^2}{N - 2}$$

$$\text{但し } z_{\alpha} = u_{\alpha} - v_{\alpha} \quad \bar{z}_1 = \frac{2}{N} \sum_1^{N/2} z_{\alpha}$$

$$\bar{z}_2 = \frac{2}{N} \left(\sum_{\frac{N}{2}+1}^N z_{\alpha} \right)$$

で推定される。 かくて、この場合系統的な並べ方は

無作為な並べ方よりもむつと有効な検定が得られる。

我々は $y_{\alpha_1} - y_{\alpha_2} = \delta$ ($\alpha = 1, \dots, N$) が既知であると假定してゐるからこそこの方法で有効な検定が得られたわけである。 しかしながら、大抵の実際の場合では、 y_{α_i} について何も知る事が出来ない事が多い。 それで、かゝる場合系統的な並べ方は検定を偏倚にするから、無作為な並べ方の方が最も安全である。

結論として、次の事が云へる (以下初に述べた号Aをつづく)