

基礎統計教育教材

1980

經濟企劃院 調查統計局

目 次

第一編 統計入門	5
第1章 序 論	7
1.1 바람직한 統計란 ?	7
1.2 어떻게 調査하겠는가 ?	8
1.3 資料의 分析	9
第2章 統計的 推定	11
2.1 定 義	11
2.2 바람직한 推定	12
2.3 古典的 推定	18
(1) 点 推定	18
(2) 区間推定	37
2.4 Bayesian 推定方法	42
第3章 統計的 檢定	59
3.1 仮設 檢定이란 ?	59
3.2 母數 檢定	65
(1) 平均의 檢定	65
(2) 比率의 檢定	67
(3) 平均值差에 대한 檢定	68
(4) 比率의 差에 대한 檢定	75
(5) 分散의 同一性에 관한 檢定	77

3 . 3 非母数的 検定	78
(1) χ^2 - 検定	78
(2) 符号検定 (the sign test)	87
(3) 測定値間の 差에 順位를 매겨 検定하는 方法 (the signed rank test)	91
3 . 4 Bayesian 意思 決定論	94
(1) 緒 論	94
(2) 仮説検定과 두 行為問題와의 比較	97
第4章 回帰와 相関	105
4 . 1 相関分析	105
(1) 相関關係의 測定	108
(2) 相関關係의 検定	113
4 . 2 回帰分析	116
(1) 直線回帰	116
(2) 非直線回帰	123
(3) 多元回帰分析	128
第二編 統計調査方法	133
第1章 統計調査一般	135
1 . 1 統計調査의 定義와 種類	135
1 . 2 統計調査의 必要性	137
第2章 全数調査와 標本調査	140

2 . 1	全数調査	140
2 . 2	標本調査	141
2 . 3	全数調査와 標本調査의 比較	141
第 3 章	統計調査의 方法	144
3 . 1	統計調査의 企劃과 準備	145
3 . 2	實際調査 (現地調査)	166
3 . 3	調査票의 審査와 集計	176
3 . 4	統計表의 作成과 分析	182
第 4 章	統計調査의 实例 - 經濟活動人口調査	190
4 . 1	調査概要	191
4 . 2	調査節次	196
4 . 3	調査票 作成	198
4 . 4	調査方法 決定의 理論的 基礎	200

第一編 統計入門

第1章 序論	1
第2章 統計的推定	11
第3章 統計的検定	59
第4章 回帰と 相関	105

第一章 序 論

우리나라의 統計年鑑에 收錄돼 있는 것을 보면 25 가지의 大分類 統計와 326 가지의 統計表가 收錄돼 있다. 이러한 모든 統計는 直・間接으로 모두 統計局의 影響을 받지 않을 수 없으며 統計局 員들은 이러한 統計의 直接生産者인 同時에 總括者인 것이다.

이러한 龐大한 統計를 生産하기 위해서는 人的, 物的 裝備와 이것을 效果的으로 構成 投入하는 機構가 必要하게 된다. 즉 사람과 돈과 組織이 될 것이다. 더 나아가서 有能한 人材와 豊富한 돈과 效率的인 組織이 있어야 바람직한 統計가 生産될 것이다.

1.1 바람직한 統計란?

어떤 統計가 바람직 하겠는가? 誤差없는 統計가 生産되는 것이 바람직 할 것이다. 물론 誤差라는 概念을 여러가지로 定義가 다르지만 여기서는 標本誤差와 非標本誤差로 区分하여 생각해 보기로 하자. 標本誤差란 部分을 調査하여 全体를 알고자 하는데서 發生하는 必然的인 情報不足에서 發生하는 誤差며, 非標本誤差란 全部를 調査하더라도 생기는 誤差를 말한다. 특히 標本誤差는 調査方法이나 實驗設計에 의해 糾明 혹은 統制되지만 非標本誤差는 그렇지 않은 경우가 흔히 있다. 특히 非標本誤差의 問題는 全數 調査의 質的인 問題로써 이것은 社会的, 政治的으로 物議를 빚는

경우도 있을수 있다. 이 非標本誤差의 原因으로는 여러가지를 들 수 있을 것이다. 그러나 大体的으로 모든것에서 그 原因을 찾을 수 있다고 하겠다. 예를 들면 「人口 및 住宅센서스」에서 女子의 年齡같은 項目은 우리나라 傳統的으로 女子들은 나이를 正確히 대기를 좀 꺼려하는 慣習이 있다. 이러한 習慣이나 傳統도 非標本誤差의 原因이 되겠다.

바람직한 統計로서는 위에서 說明한 바와같이 우선 誤差가 작아야 할 것이다. 또한 費用이 可及的이면 最小로 드는 것도 빼놓을 수 없는 것이다. 費用이 적을뿐 아니라 時間도 적게 들고 最小의 調査로 最大의 效果를 얻을 수 있다면 바람직스러운 統計가 될 것이다.

1.2 어떻게 調査하겠는가?

우선 全部 調査를 하느냐 部分 調査를 하느냐는 주어진 与件 (費用, 時間, 人員...) 下에서 可能한 調査가 무엇이냐 또 目的이 어디에 있느냐에 따라 決定하게 될 것이다. 많은 指定統計가 全數 調査를 한 것이고 統計年鑑에 收錄된 또한 많은 統計가 標本 調査를 한 것이다.

標本 調査를 할 경우에는 客觀的인 調査法 (確率 調査) 과 主觀的인 調査法이 있다 하겠다. 前者는 全体母集團에 관한 어떤 推論 혹은 意思決定에 目的을 둔 것이고 後者は 部分이라는 標本自體의

技術 혹은 意思決定으로 끝나게 된다.

客觀的 標本調査는 주어진 條件下에 最善의 目的을 達成하기 위해서는 어떤 原理에 立脚해서 設計, 進行, 分析이 이루어 져야 할 것이다. 이러한 原理를 通稱한다면 바로 統計學의 原理라 하겠다.

1.3 資料의 分析

모든 統計表는 調査項目의 組合에 관한 內容을 表示하고 있다고 볼 수 있다. 이 調査項目은 알고자 하는 目的을 具體적으로 表示한 것이라 하겠다. 이 調査項目은 일종의 統計的變數를 나타낸다고 볼 수 있다. 이 變數를 連續變數와 離散變數로 나누어 생각하는 것이 보통이다. 또한 이들 變數의 測定 혹은 調査된 水準을 測定值의 水準 혹은 測定值의 尺度라고 부른다. 測定值의 尺度는

(1) 名目尺度

(2) 順序尺度

(3) 區間尺度

(4) 比率尺度

로 나눈다. 위의 名目尺度와 順序尺度는 非母數統計學 (Non-parametric statistics)의 大體的인 客體이며 母數統計學은 區間尺度와 比率尺度를 主對象으로 한다.

위의 4가지 尺度로 되어 있는 統計表를 가지고 먼저 簡單히

要約을 하는 方法으로는 代表値와 分散度, 의도, 尖度 등 特性値를 計算하거나 推出해 내는 作業일 것이다.

代表値는 여러 가지 平均値나 位數등을 들수 있으며 分散度에는 範圍나 分散概念들이 있고 의도나 尖度는 3次, 4次 積率概念들로 表示되는 것이 보통이다.

또다른 要約方法으로는 度數分布를 그리거나 度數分布를 函數形態로 導出하는 것이라 하겠다.

度數分布는 確率的인 概念인 相對度數로서 적절히 表現 되는데 確率이라는 것은 반드시 相對度數의 概念만은 아니다. 예컨대 確率을 相對度數로 보는 見解도 있고 相對度數의 極限概念으로 보는 見解 또는 測度論(measure theory)의 立場으로 또는 믿음의 정도(degree of belief) 등 多樣한 見解가 있다. 하여튼 資料를 要約하는 方法의 하나로 度數分布·혹은 頻度函數도 要約한다면 統計資料의 綜合的인 要約方法이라 하겠다.

어떤 方法으로든 要約된 統計資料를 가지고 마지막 推論分析 혹은 意思決定過程을 客觀的으로 妥當한 最適決定을 한다는 것은 普通 古典的 統計學에서는 推定 檢定이라한다. 그러나 現代統計學에서는 不確定的現象에 관한 意思決定의 하나로 看做하면 구태여 推定原理와 檢定原理가 따로 있는것이 아니고 不確定的인 現象下에서 意思決定原理로 統合된다고 볼 수 있다.

그러나 本講義에서는 편의상 推定 檢定을 分離하여 說明하기로 한다. 끝장에서 2變數이상의 分析例로서 回歸分析을 簡單히 說明한다.

第 2 章 統計的 推定

本章에서는 統計的 推定에 대하여 다루게 되는데 1 節에서는 推定에 대한 定義에 대하여, 2 節에서는 바람직한 推定量 (Good Estimation) 에 관하여, 3 節에서는 古典的, 統計的 推定에 대하여 略述하는데 小節로는 点推定과 区間推定을 나누어서 說明하고 4 節에서는 Bayesian 方法에 대하여 說明하고자 한다.

2.1 推定の 定義

確率変數 X 의 分布函數의 형태를 어떤 이유로 해서 알고 있는지 혹은 이럴것이라고 假定할 수 있는 경우도 그것은 몇개의 未知母數를 包含하고 있는것이 보통이다. 만약 母數의 값을 모두 알고 있다면 分布函數는 確定되므로 推測 統計的 研究의 必要性이 반감된다. 그래서 標本을 利用하여 母集團母數 (未知인)의 값을 얻을때 이 얻는과정을 推定 (Estimation)이라 하고 이러한 推定을 통하여 未知인 母集團母數를 推定하기 위하여 標本을 觀測하였을때 이 觀測에서 얻은 어느 특정한 값을 推定值 (Estimate)라 하며 推定하는데 있어서 標本이 數字로 特定되기 전에 任意 標本 (Random Sample)과 函數關係를 갖는 것을 推定量 (Estimator)이라 한다. 가령 任意標本을 $X_1, X_2, \dots, X_n$ 이라 하면 平均인 $\bar{X}$ 를 이 標本이 抽出된 母集團의 平均인 μ 의 推定量이라

한다. 一般적으로 母集團의 確率密度函數(p.d.f) $f(x, \theta_1 \cdots \theta_K)$ 의 모양은 알고 있으나 그것은 $\ell (\leq K)$ 개의 未知母數 $\theta_1 \cdots \theta_\ell$ 을 包含하고 있다. 이때 標本 $x_1, x_2, \cdots, x_n$ 에 관한 ℓ 개의 1個函數 $t_i(x_1, \cdots, x_n), i = 1, 2, \cdots, \ell$ 를 취하고 그 값을 θ_i 의 推定値로 삼는 것이 點推定(Point Estimation)이다. 예를들면 推定에서 單一한 값을 얻는 標本平均, 標本標準偏差등을 母平均, 母集團偏差등의 點推定이라 한다. 區間推定은 推定値의 區間 $[a, b]$ 를 지정하고 未知의 母數 θ 가 그 속에 包含된다고 하는 형식으로 θ 를 推定하려는 것이다. 따라서 推定에는 點推定과 區間推定이 있다.

2.2 바람직한 推定量

推定量의 性質은 小標本(Small Sample) 혹은 有限標本(finite sample)에 대한 것과 大標本(large sample)에 대한 것으로 구분된다. 統計的 推定에 바람직한 推定量은 그 分布가 真正한 母數(true parameter)에 가능한 한 集中되어 있는 것이라 하겠다. 그래서 推定量의 分布에서 그 위치와 모양을 말해 주는 平均과 分散이 推定量의 性質을 평가하는데 대한 對象이 되고 바람직한(좋은) 推定量인가에 대한 決定基準은 小標本인 경우 (1) 不偏性(unbiasedness) (2) 最小分散(minimum variance) 등이고 大標本인 경우 (1) 不偏性 (2) 一致性(consistency)

(3) 有効性 (Efficiency) 등이다. 그러면 小標本에 대한 推定量의 性質에 대하여 먼저 알아 보기로 한다. 바람직한 推定量의 性質은 標本の 크기를 점점 크게 함에 따라 推定値가 母數값에 수렴하는 성질일 것이다.

a) 不偏性 (Unbiasedness)

만약 $E(t) = \theta$ 라면 $t = t(x_1, x_2, \dots, x_n)$ 는 θ 의 不偏推定量 (推定値) 이다. 이것은 確率變數 t 가 推定하려는 母數 θ 를 平均으로 갖는 分布에 따른다는 것이다. 예를들면 $E(\bar{X}) =$

$$\frac{1}{n} \sum_{i=1}^n E(x_i) = \frac{1}{n} \cdot n E(X) = E(X) = \mu \text{ 다. 이것을 보면 標本平均}$$

은 母平均의 不偏推定量이 된다. 또 다른 예로서 어떤 統計量에 있어서 標本の 크기 n 인 標本分散의 期待値를 살펴보자. 標本

$$\text{分散이 } S^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \text{ 이라 하자.}$$

이때 S^2 의 期待値는

$$\begin{aligned} E[S^2] &= E\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right] \\ &= E\left\{\frac{1}{n} \sum_{i=1}^n [(x_i - \mu) - (\bar{x} - \mu)]^2\right\} \\ &= E\left[\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 - (\bar{x} - \mu)^2\right] \\ &= \frac{1}{n} \sum_{i=1}^n E(x_i - \mu)^2 - E(\bar{x} - \mu)^2 \\ &= \frac{1}{n} \sum_{i=1}^n \sigma^2 - \sigma^2 \frac{1}{n} \\ &= \sigma^2 - \frac{\sigma^2}{n} \end{aligned}$$

이것은 S^2 이 σ^2 의 不偏推定値가 아님을 말해 주고 있다. 즉

$\frac{\sigma^2}{n}$ 라는 偏倚性 (bias) 이 생긴다. 따라서 不偏推定値를 구하고자 할 때에는 母分散推定에 있어서 標本을 결합하는 方法에 주의하지 않으면 안된다. S^2 의 偏倚性을 克服하기 위하여 $\frac{n}{n-1}$ 을 곱한 것의 期待値를 취하게 되는 것이다. 즉 다음과 같이 된다.

$$E \left[\frac{n}{n-1} S^2 \right] = \left(\frac{n}{n-1} \right) \cdot \left(\frac{n-1}{n} \right) \cdot \sigma^2 = \sigma^2$$

S^2 가 σ^2 의 不偏推定量 $\hat{\sigma}^2$ 와 같게 되려면 S^2 에 $\left(\frac{n}{n-1} \right)$ 을 곱하여야 한다.

$$\hat{\sigma}^2 = \frac{n}{n-1} S^2 = \frac{n}{n-1} \left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right] = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

따라서 $\hat{\sigma} = S$ 가 되려면

$$S = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$$

이 되어야 한다. 즉 標本分散 S^2 는 母分散 σ^2 의 不偏推定量이다.

b) 最小分散 (minimum variance)

不偏性の 性質이 推定에 있어서 하나의 바람직한 性質이기는 하나 그것보다 더 중요한 것은 어떤 의미에서 推定하려는 母數에 접근해 간다는 性質이다.

따라서 두개의 統計量 t, t' 가 있을때 t 는 θ 에 접근해 가는 統計量이고 t' 는 그렇지 않으며 또한 t 는 偏向性이 있고 t' 는 그렇지 않고 不偏推定量이라 하면 母數 θ 를 推定할때 推定量으로서 t 를 택하게 된다. 어떤 합리적인 접근성의 정의에 대해 두 推定値중에서 어느것이 더 母數 θ 에 접근하고 있는나를 決定하는 것이 불가능하기 때문에 θ 의 접근 정도 대신에 t 의 變異度를 계산한다. 이 變異정도를 계산하는 尺度로서 分散이나 標準偏差를 使用한다. t_1, t_2 가 서로 비교하고자 하는 θ 의 推定値라 하자. t_1 가 t_2 보다 良好하려면 모든 가능한 θ 의 값에 대하여 $E(t_1 - \theta)^2 \leq E(t_2 - \theta)^2$ 이어야 하며 적어도 하나의 θ 의 값에 대하여는 부등호가 성립해야 한다. 즉 $Var(\hat{\theta}) \leq Var(\hat{\theta})$

但 $\hat{\theta}$ 는 $\hat{\theta}$ 外의 推定量

이렇게 되면 $\hat{\theta}$ 는 다른 어떠한 推定量중에서도 가장 작은 分散을 갖는 推定量이다. 만약 θ 의 推定量인 $\hat{\theta}$ 가 不偏推定値이면서 最小分散을 갖는다면 이 推定量 $\hat{\theta}$ 는 母數 θ 의 最良不偏推定値가 된다. 만약 推定量 $\hat{\theta}$ 가 標本觀測의 線型函數이고 동시에 最良不偏推定値이면 $\hat{\theta}$ 는 θ 의 最良線型不偏推定量 (the best linear unbiased estimator, blue)이 된다. 예를 들면 標本平均 $\bar{x}$ 가 標本觀測의 線型函數이고 母平均 μ 의 最小分散을 가진 不偏推定量이면 이 標本平均 $\bar{x}$ 는 母平均 μ 의 BLUE이다. 大標本 (漸近標本이라고 함)의 경우 推定量의 性質도 小標本の 경우와 비슷하기도 하나 標本の 크기가 커짐에 따라 당해 推定量의 分布가 점점 어느

特定한 分布로 接近하게 되고 이렇게 된 分布를 그 推定量의 漸近分布 (asymptotic distribution)라 한다. 漸近分布도 역시 積率 (moments)에 의하여 특정지어 지는데 그 중에서도 漸近平均 (asymptotic mean)과 漸近分散 (asymptotic variance)이 가장 중요한 것이다. 다음과 같은 推定量의 漸近性質이 있다.

a. 漸近的 不偏性 (asymptotic unbiasedness)

만약 $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$

단, $\lim_{n \rightarrow \infty}$ = 標本의 크기 n 이 無限大로 접근함에 따른 極限

이면 $\hat{\theta}$ 는 θ 의 漸近的 不偏推定量이 된다. 만약 어느 推定量이 不偏推定値이면 이 推定量은 역시 漸近的 不偏이 된다. 그러나 漸近的 不偏推定量은 반드시 不偏推定値가 되는 것이 아니다.

예를들면 標本分散이 이러하다. n 이 無限大로 접근함에 따라 $\frac{n-1}{n}$ 이 1로 되기 때문이다. 즉

$$\begin{aligned} E(S^2) &= \frac{1}{n} E \left[\sum_{i=1}^n (t_i - \bar{x})^2 \right] = \frac{1}{n} \sum_{i=1}^n \sigma^2 = \sigma^2 \\ &= \sigma^2 - \frac{\sigma^2}{n} \end{aligned}$$

에서 偏倚 $\frac{\sigma^2}{n}$ 가 0으로 된다.

b) 一致性 (consistency)

標本의 크기 n 이 無限大에 접근함에 따라 推定量 $\hat{\theta}$ 의 分布가 한 點으로 收斂하게 될때 이 點을 $\hat{\theta}$ 의 確率極限 (proba-

bility limit)라 하는데 Plim로表記된다. 즉, 다음과 같은 것을 말한다.

$$\lim_{n \rightarrow \infty} P(\theta^* - \varepsilon \leq \hat{\theta} \leq \theta^* + \varepsilon) = 1$$

단 θ^* 는 θ 와 같을 수도 다를 수도 있는 어느 點. $\varepsilon =$ 작을 수 있는데까지 작아진 어떤 假想的인 陽의 數

$$\text{만약 } P\lim_{n \rightarrow \infty} (|\hat{\theta} - \theta| \leq \varepsilon) = 1 \text{ 또는}$$

$P\lim_{n \rightarrow \infty} (|\hat{\theta} - \theta| > \varepsilon) = 0$ 이 성립하면 이 $\hat{\theta}$ 를 θ 의 一致推定量이라 한다. 하나의 推定量이 不偏인지 아닌지를 아는 것은 비교적 쉬운일이고 두 不偏推定量의 分散을 비교하는 것은 아주 간단한 일이다. 그러나 一致性을 증명하기는 쉬운일이 아니다. 다음 식은 때로는 아주 유용하게 사용된다.

$\hat{\theta} = t(X_1, X_2 \dots X_n)$ 을 母數 θ 의 推定量이라 할 때 $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$ 이고 $\lim_{n \rightarrow \infty} V(\hat{\theta}) = 0$ 이면 $\hat{\theta}$ 는 θ 의 一致推定量이다.

c) 漸近的 有效性 (asymptotic efficiency)

만약 $\hat{\theta}$ 가 θ 의 一致推定量이면서 다른 어떤 一致推定量보다 가장 작은 分散을 갖고 있고 有限平均과 有限分散을 갖고 漸近的 分布를 하고 또는 推定量이면 이것을 θ 의 漸近的 有效推定量이라 한다.

예를 통하여 바람직한 推定量을 알아보자. 전구를 만드는데 있어서 전구에서 抽出한 n 개의 標本 ($X_1, X_2 \dots X_n$)에 K 개의

不良品이 들어있다: 즉 $Y = \sum_{i=1}^n X_i = K$ 라 한다. 즉 i 번째로

抽出한 전구가 不良品이면 $X_i = 1$, 良品이면 $X_i = 0$, $i = 1, 2$

... n 로 나타내면 不良品の 數 Y 는 二項分布를 따른다고 한다.

母數 (不良比) P 의 推定量으로 標本의 不良比 $\hat{p} = \frac{Y}{n}$ 를 취하면

$$E(\hat{p}) = E\left(\frac{Y}{n}\right) = \frac{1}{n} np = P \quad \text{이므로 } \hat{p} \text{는 不偏推定量이다.}$$

$$V(\hat{p}) = V\left(\frac{Y}{n}\right) = \frac{1}{n^2} (np)(1-p) = p(1-p)/n$$

이고 $n \rightarrow \infty$ 이면 $V(\hat{p}) \rightarrow 0$ 이므로 $\hat{p}$ 는 一致推定量이다. 만일

p 의 推定量으로 다음과 같이 정의된 p^* 를 취한다고 하자, 첫

번째 택한 전구가 不良品이면 $P^* = 1$ 그렇지 않으면 $P^* = 0$

$$E(P^*) = 1 \cdot P(X=1) + 0 \cdot P(X=0) = P$$

$V(P^*) = P(1-P)$ 이므로 P^* 는 不偏推定量이지만 一致推定量은 되지 못한다. 따라서 꼭 좋은 바람직한 推定量은 되지 못한다.

2.3 古典的 推定方法

2.3.1 點推定 (point estimation)

點推定이 흔히 알고 있는 보통 推定法인데 이는 確率變數의 觀察値에 의한 계산으로 부터 얻어진 하나의 數值가 되며

母數의 近似値로써 取扱하게 되는 것이다. 예컨대 어떤 기계에

의하여 생산되는 연속적인 50개의 部分品중 觀察된 比率 P 의

點推定이 되는 것이다. 點推定 方法에는 대체로 積率法 (method

of moments), 最小自乘法 (least squares method), 最尤法 (maximum likelihood method) 그리고 其他方法 (other methods)가 있다.

1) 積率法 (method of moments)

대부분의 문제에 있어서 1次的 積率과 2次的 積率에 대해서만 관심을 두는 것이 보통이다. 어떤 몇몇의 문제에서는 4次的 積率까지 사용되며 4次的 積率보다 高次的 積率을 사용하는 경우는 극히 드물다. 이에 대한 한가지 이유로서 抽出實驗을 反復하는 경우 高次的 積率은 아주 不安定하므로 高次積率에서 信賴할 만한 追加的인 情報을 얻을 수 없기 때문이다. 原点에 관한

1次的 積率 m' 를 平均 (mean)이라 부르며 보통 $\bar{x}$ 로 표시한다.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^h x_i f_i \quad (1)$$

단 x_i : i 번째의 階級에 대한 階級값

f_i : 그 階級の 絕對次數

h : 階級の 數

n : 絕對次數의 總合

분류되지 않은 자료의 경우 $\bar{x}$ 는 한 모임의 數의 平均 (average)으로서 잘 알려진 공식이 된다. 이 공식은 加重平均에 관한 공식이라고도 한다. 그런데 加重平均은 분류된 자료에 適応할 수 있는 공식의 한 종류에 지나지 않는다. x_i 와 f_i 가 그렇게 크지 않거나 계산기를 이용할 수 있으면 $\bar{x}$ 는 定義式으로 쉽게

계산할 수 있다. 그렇지 않은 경우에는 새로운 變數를 도입하여
간편셈을 함으로써 등간격의 계급으로 분류되어 있는 度數分布表에
서는 많은 시간을 절약할 수 있다. 지금 整數值만을 취하는 새
로운 變數 μ 를 다음과 같이 정의한다.

$$x_i = C\mu_i + x_0 \quad (2)$$

여기서 C 는 계급폭이며 x_0 은 편하도록 택한 계급값이다. 보통
 x_0 은 分布의 中心부근에 있는 계급값으로 택하는 것이 계산상
편리하다. 이것을 (1)에 있는 x_i 에 대입하면

$$\begin{aligned} \bar{x} &= \frac{1}{n} \sum_{i=1}^h (C\mu_i + x_0) \cdot f_i \\ &= \frac{1}{n} \sum_{i=1}^h (C\mu_i f_i + x_0 f_i) \\ &= \frac{1}{n} \sum_{i=1}^h (\mu_i f_i + \frac{1}{n} \sum_{i=1}^h x_0 f_i) \end{aligned}$$

x_0 과 C 는 常數이므로 總合記号앞으로 나오게 되어 다음과 같이
된다.

$$\bar{x} = C \cdot \frac{1}{n} \sum_{i=1}^h \mu_i f_i + x_0 \frac{1}{n} \sum_{i=1}^h f_i$$

(1)로부터 C 의 係數는 $\bar{\mu}$ 이며, μ 의 정의로부터 x_0 의 係數는

1이다. 따라서

$$\bar{x} = C \bar{\mu} + x_0 \quad (3)$$

$\bar{\mu}$ 는 비교적 쉽게 계산할 수 있으므로 $\bar{x}$ 의 값은 계산기의 도움
이 없어도 매우 간단하게 구할 수 있다.

變異라 하면 位置測度들에의 資料의 變異를 뜻하는 것이 보통이다. 여기서 位置의 測度로서 平均을 사용하므로 積率에 의하여 變異의 測度を 얻자면 平均에 관한 積率을 도입할 必要가 있다.

즉 平均에 관한 K次 積率은

$$m_k = \frac{1}{n} \sum_{i=1}^h (x_i - \bar{x})^k \cdot f_i \quad (4)$$

平均에 관한 2次의 積率 m_2 가 變異의 測度로서 사용할 수 있음을 살펴보자. 變異의 測度는 측정의 단위로서 資料와 동일한 것이라야 편리하므로 보통 $\sqrt{m_2}$ 를 사용하게 된다. 이것을 標準偏差 (standard deviation)라 부르며 S로서 표시한다. 즉

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^h (x_i - \bar{x})^2 \cdot f_i} \quad (5)$$

평균에 관한 2次의 積率 S^2 은 경우에 따라서는 變異의 測度로서 標準偏差보다 편리하며 分散 (variance)라 불리운다.

(5)식은 계산하는데 불편하므로 간단한 式으로 유도하면 $x_i - \bar{x} = C(\mu_i - \bar{\mu})$ 이므로 ((2)와 (3)으로부터)

$$\begin{aligned} & \frac{1}{n} \sum_{i=1}^h (x_i - \bar{x})^2 \cdot f_i \\ &= \frac{1}{n} \sum_{i=1}^h C^2 (\mu_i - \bar{\mu})^2 \cdot f_i \\ &= \frac{C^2}{n} \sum_{i=1}^h (\mu_i^2 - 2\mu_i \bar{\mu} + \bar{\mu}^2) \cdot f_i \end{aligned}$$

$$= C^2 \left(\frac{\sum_{i=1}^h \mu_i^2 f_i}{n} - 2\bar{\mu} \frac{\sum_{i=1}^h \mu_i f_i}{n} + \bar{\mu}^2 \frac{\sum_{i=1}^h f_i}{n} \right)$$

$$= C^2 \left(\frac{\sum_{i=1}^h \mu_i^2 f_i}{n} - \bar{\mu}^2 \right)$$

따라서 $S = \sqrt{\frac{\sum_{i=1}^h \mu_i^2 f_i}{n} - \bar{\mu}^2}$

분류되지 않은 자료에서는 $S = \sqrt{\frac{\sum x_i^2}{n} - \bar{x}^2}$ 이 (5) 보다

훨씬 편리하다.

예를들어 보자.

아래표는 電話의 通話時間을 반올림하여 秒單位까지 측정한 것을 1,000 회 기록한 것이다.

x	f	u	μf	$\mu^2 f$
49.5	6	-4	-24	96
149.5	28	-3	-84	252
249.5	88	-2	-176	352
349.5	180	-1	-180	180
449.5	247	0	0	0
549.5	260	1	260	260
649.5	133	2	266	532
749.5	42	3	126	378
849.5	11	4	44	176
949.5	5	5	25	125
合 計	1,000		257	2,351

平均 $\bar{x} = C\bar{\mu} + x_0$ 이므로

$$\bar{x} = 100 \cdot \left(\frac{257}{1006} \right) + 449.5 = 475.2$$

標準偏差는

$$S = C \cdot \sqrt{\frac{\sum_{i=1}^m \mu_i^2 f_i}{n} - \bar{\mu}^2} \quad \text{이므로}$$

$$S = 100 \sqrt{\frac{2351}{1000} - (257)^2} = 151$$

2) 最小自乘法 (least squares method)

주어진 점의 集合에 效果的으로 曲線을 맞추는 문제는 본질적으로 曲線의 母數 (parameter) 를 效果的으로 推定하는 문제이다. 이러한 母數를 推定하는 方法은 여러가지가 있지만 가장 잘 알려진 것이 다음에 說明하고자 하는 最小自乘法 (least squares method) 이다.

원래 母數의 推定에는 당연히 偏差 (error) 을 수반한다. 그 리하여 있을 수 있는 偏差를 되도록 적게하는, 그러한 성격을 밝히는 것이 요구되는 條件이다. 그 中 最小自乘法은 母數에 대한 偏差의 供給을 最小로 하는 推定值를 얻는 方法이라 할 수 있다. 母數 그 自体는 一般的으로 알 수 없는 母值이지만 어쨌든 偏差의 存在는 豫想되고 그 方向은 正負 (플러스, 마이너스) 의 어느 쪽이든지 나타나기 때문에 理論上 그러한 推定方法이 요구되는 性質이다. 가령 어느 任意標本 $X_1, X_2, \dots, X_n$ 이 있는데 각

X_i 는 同一한 平均 μ 와 分散 σ^2 를 갖는다고 하자. 이에 대한 各各의 實際觀測値는 다음과 같은 關係로 표시될 수 있다.

$$X_i = \mu + \mu_i$$

여기서 $E(X_i) = \mu$ 라는 것은 다 아는 사실이다. 따라서 $E(\mu_i) = 0$ 은 당연하다. 우리는 μ 를 推定하고자 하는데 最小自乘法에 의한 推定은 $\sum_{i=1}^n (X_i - \mu)^2$ 를 가장 작게 할 수 있는 μ 의 推定量을 찾으려는 것이다. 즉 어떠한 μ 의 값에 대해서도 다음과 같은 關係가 成立한다고 하면

$$\sum_{i=1}^n (X_i - \hat{\mu})^2 \leq \sum_{i=1}^n (X_i - \mu)^2$$

$\hat{\mu}$ 는 μ 의 最小自乘推定量 (least squares estimator)가 된다.

여기서

$$X_i = \hat{\mu} + e_i$$

라고 놓으면 $\hat{\mu}$ 는 다음과 같이 偏差를 供給하여 合한 것을 最小化시키므로써 求해질 수 있다.

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (X_i - \hat{\mu})^2$$

$\hat{\mu}$ 에 대한 식의 一次微分을 0과 같게 놓으면 바로 求해진다.

$$\frac{\partial \sum_{i=1}^n e_i^2}{\partial \hat{\mu}} = -2 \sum_{i=1}^n (X_i - \hat{\mu}) = -2 \left[\sum_{i=1}^n X_i - n\hat{\mu} \right] = 0$$

$$\sum_{i=1}^n X_i = n\hat{\mu}$$

$$\hat{u} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

이와같이 最小自乘法에 의하여 구한 推定量 $\hat{u}$ 는 標本平均 $\bar{X}$ 와 같다.

지금 一例로써 어떠한 두 統計系列의 關係 즉 統計值 X 에 대한 Y 의 分布를 본다 하고 이를 규정하는 진정한 趨勢直線이 있어서 그것이


$$Y_i = a + b X_i$$

라 하자. 이 식을 眞(母) 回歸線 (true or population regression line)이다. 여기서 a, b 를 구한다는 것은 사실상 불가능하고 X, Y 의 標本觀測值 (sample observation)를 가지고 a, b 를 推定해야 한다. $\hat{a}$ 를 a 의 推定量 $\hat{b}$ 를 b 의 推定量이라 하면 X, Y 의 推定된 關係는 $Y_i = \hat{a} + \hat{b} X_i + e_i$ ($i = 1, 2, 3 \dots n$)가 되고 X, Y 의 推定된 回歸線 (estimated regression line) 혹은 標本回歸線 (sample regression line)을 나타내는 식은 다음과 같다.

$$\hat{Y}_i = \hat{a} + \hat{b} X_i \quad (i = 1, 2, 3, \dots n)$$

標本觀測을 二次元平面위에 표시해 보면 그림에서와 같이 흩어진 點들이 될 것이다.

標本回歸線은 이 점들을 가장 잘 대표하는 線으로 그어져야 한다. 이렇게 그어진 線을 흔히 適合線 (fitted line)이라 한다. 이 適合線이 얼마나 잘 그어졌느냐 하는 것은 標本回歸線 즉 平均



<그림> 두 變數간의 關係

에서 點들이 양쪽으로 떨어진 거리 즉 偏差를 最小로 하느냐 하는것이다. 偏差가 兩便으로 散在하기 때문에 前提條件에 의하여 偏差의 和는 0이 된다. 그래서 各偏差를 제곱하여 合한 것 (自乘合)이 最小가 되면 適合線은 좋게 잘 그어진 것이 된다. 즉 그 偏差의 自乘合이 最小가 되게 하는 것이다. 母數 a, b 는 眞回歸線의 位置와 기울기이므로 이 自乘合이 最小가 되게 하여 구한 a, b 는 가장 좋은 適合線을 구하였다는 것이 되므로 여기서 구한 $\hat{a}, \hat{b}$ 는 眞回歸線母數 a, b 의 推定量이 된다. 實際標本觀測值 즉 흩어진 點들을 나타내는 關係가 위에서 밝힌 바 있는
$$Y_i = \hat{a} + \hat{b} X_i + e_i \quad (1)$$

이고 그 平均인 標本回歸線을 나타내는 것이 마찬가지로 위에서

말한바와 같이

$$\hat{Y}_i = \hat{a} + \hat{b} X_i \quad (i = 1, 2, 3 \dots n) \quad (2)$$

이다. 平均과 各点과의 偏差인 残差 (residual) 는 (2)를 (1)에서 빼줌으로써 구할 수 있다.

$$e_i = Y_i - \hat{Y}_i = Y_i - \hat{a} - \hat{b} X_i \quad (3)$$

($\hat{Y}_i = \hat{a} + \hat{b} X_i$ 를 代入)

이 残差를 제곱하여 합하면 다음과 같이 된다.

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - \hat{a} - \hat{b} X_i)^2$$

우리는 이것을 最小로 해야 한다. 이렇게 하기 위하여 즉 必要條件으로 이 式을 偏微分하여 0과 같게 놓아야 한다. 그런데 우리가 구하고자 하는 것은 $\hat{a}$, $\hat{b}$ 이므로 $\hat{a}$, $\hat{b}$ 에 대하여 偏微分을 해야 한다.

$$\frac{\partial \sum e_i^2}{\partial \hat{a}} = \frac{\partial \sum (Y_i - \hat{a} - \hat{b} X_i)^2}{\partial \hat{a}} = \sum 2(Y_i - \hat{a} - \hat{b} X_i) \quad (-1)$$

$$= -2 \sum (Y_i - \hat{a} - \hat{b} X_i) = 0$$

$$\frac{\partial \sum e_i^2}{\partial \hat{b}} = \frac{\partial \sum (Y_i - \hat{a} - \hat{b} X_i)^2}{\partial \hat{b}} = \sum 2(Y_i - \hat{a} - \hat{b} X_i) (-X_i)$$

$$= -2 \sum X_i (Y_i - \hat{a} - \hat{b} X_i) = 0$$

이것을 整理하여 놓으면

$$\sum Y_i = n \hat{a} + \hat{b} \sum X_i \quad (4)$$

$$\sum X_i Y_i = \hat{a} \sum X_i + \hat{b} \sum X_i^2 \quad (5)$$

와 같이 된다. 이 두 식을 標本回帰線의 正規方程式 (normal equations) 이라 한다. 이 正規方程式을 $\hat{a}$ 와 $\hat{b}$ 에 대해서 풀면 다음과 같이 된다.

$$\hat{a} = \frac{\sum X_i^2 \sum Y_i - \sum X_i \sum X_i Y_i}{n \sum X_i^2 - (\sum X_i)^2} \quad (6)$$

$$\hat{b} = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{n \sum X_i^2 - (\sum X_i)^2} \quad (7)$$

標本觀測值 그대로를 計算하여 代入하면 위와같은 最小自乘法에 의하여 推定한 $\hat{a}$ 와 $\hat{b}$ 의 값이 주어진다. 이것을 偏差 즉 $x_i = X_i - \bar{X}$, $y_i = Y_i - \bar{Y}$ 로 보기 위하여 (4)의 各項을 n 으로 나누면

$$\bar{Y} = \hat{a} + \hat{b} \bar{X} \quad (8)$$

$$\left(\bar{Y} = \frac{1}{n} \sum Y_i \quad \bar{X} = \frac{1}{n} \sum X_i \right)$$

가 된다. 여기에서 最小自乘法에 의하여 推定된 回帰線은 平均点 $(\bar{X}, \bar{Y})$ 를 지나게 됨을 볼 수 있다.

式 (8)을 式 (2)에서 빼면

$$\begin{aligned} \hat{Y}_i - \bar{Y} &= \hat{a} + \hat{b} X_i - (\hat{a} + \hat{b} \bar{X}) \\ &= \hat{b} (X_i - \bar{X}) \end{aligned}$$

가 된다. 이것을 다시 쓰면 다음과 같은 回帰線을 나타내는 식이 된다.

$$\hat{y}_i = \hat{b} x_i \quad (9)$$

또한 式 (1)에서 式 (8)을 빼주면 다음과 같다.

$$y_i = \hat{b} x_i + e_i$$

式 (3)에서와 마찬가지로 殘差와 그 自乘은 다음과 같이 구해진다.

$$\begin{aligned} e_i &= y_i - \hat{y}_i = y_i - \hat{b} x_i \\ \sum e_i^2 &= \sum (y_i - \hat{b} x_i)^2 \end{aligned} \quad (10)$$

이것을 微分하여 0으로 놓고 $\hat{b}$ 에 대하여 풀면 다음과 같이 된다.

$$\begin{aligned} \frac{\partial \sum e_i^2}{\partial \hat{b}} &= \frac{\partial \sum (y_i - \hat{b} x_i)^2}{\partial \hat{b}} \\ &= -2 \sum x_i (y_i - \hat{b} x_i) = 0 \\ \hat{b} &= \frac{\sum x_i y_i}{\sum x_i^2} \end{aligned} \quad (11)$$

式 (8)을 $\hat{a}$ 에 대하여 풀면

$$\hat{a} = \bar{Y} - \hat{b} \bar{X} \quad (12)$$

가 된다. 式 (12)은 標本單純回帰線의 위치를 그리고 式 (11)은 標本單純回帰線의 기울기를 測定하는 것이므로 기억해야 할 重要한 公式이다.

예를들면 X, Y에 대한 資料는 1965 ~ 1974年間の 우리나라 1970年 不變價格國民總生産 (X)과 民間消費支出 (Y)이다.

表를 작성하여 계산된 數字들을 위 公式에 代入해 넣으면 다음과 같은 $\hat{a}$, $\hat{b}$ 의 數値를 얻게 된다.

$$\hat{a} = \bar{Y} - \hat{b} \bar{X} = 183.0 - (0.62)253.8 = 25.64$$

$$\hat{b} = \frac{\sum x_t y_t}{\sum x_t^2} = \frac{33008.0}{53321.6} = 0.62$$

이것을 흔히 Y 를 X 에 回歸시켜 $\hat{a}$ 와 $\hat{b}$ 를 推定한다고도 한다.
위의 數値를 式 (2)에 넣으면 다음과 같은 回歸線을 나타내는 式이 된다.


$$\hat{Y}_t = 25.64 + 0.62 X_t$$

X 의 標本觀測値를 式에 넣으면 $\hat{Y}$ 이 計算된다. 이것을 推定 또는 計算된 Y 라고도 한다. 本例題의 結果를 나타낸 그림이 아래와 같게 된다.

1965 ~ 1974 년간 우리나라 國民總生産(X)과 國民消費支出(Y)
(1970 년 不變價格)

(單位 : 100 億圓)

t	X_t	Y_t	X_t^2	x_t $(X_t - \bar{X})$	y_t $(Y_t - \bar{Y})$	$x_t \cdot y_t$	x_t^2	y_t^2	$\hat{Y}_t$ $(\hat{a} + \hat{b}X_t)$	e_t $(Y_t - \hat{Y}_t)$	e_t^2
1	153	120	23409	-100.8	-63	6350.4	10160.64	3969	120.50	-0.50	0.25
2	172	128	29584	-81.8	-55	4499.0	6691.24	3025	132.38	-4.38	19.18
3	185	140	34225	-68.8	-43	2958.4	4733.44	1849	140.34	-0.34	0.12
4	209	155	43681	-44.8	-28	1254.4	2007.04	784	155.22	-0.22	0.05
5	240	171	57600	-13.8	-12	165.6	190.44	144	174.44	-3.44	11.83
6	259	188	67081	5.2	5	26.0	27.04	25	186.22	1.78	3.17
7	283	208	80089	29.2	25	730.0	852.64	625	201.10	6.90	47.61
8	302	223	91204	48.2	40	1928.0	2323.24	1600	212.88	10.12	102.41
9	352	242	123904	98.2	59	5793.8	9643.24	3481	243.88	-1.88	3.53
10	383	255	146689	129.2	72	9302.4	16692.64	5184	263.10	-8.10	65.61
合計	2538	1830	697466	0	0	33008.0	53321.60	20686		0.06	253.76



<그림> 回帰線实例

3) 最尤法 (maximum likelihood method)

最尤法은 推定量을 구하는데 있어서 보다 일반적인 方法으로 認定받고 있으나 이 方法에 의하여 구해진 推定量은 大標本에서 좋은 性質을 가질 수 있는데 小標本에서는 必然적으로 不偏이 되는 것은 아니다. 最小自乘法은 母數에 대한 統計偏差의 제곱을 최소로 만드는 그러한 推定値를 구하는 方法이었지만 널리 쓰이는 또 하나의 推定法이 바로 最尤法이다. 이 方法은 지목되는 標本이 나타나는 確率을 最大化하는 그러한 母數의 決定法이다. 그것은

말하자면 나타난 現象 (統計結果)에 의하여 일정한 分布條件 아래서 그와같은 現象이 일어나는 確率을 最大로 하는 母數의 論理的 推定方法이다. 이는 R.A. Fisher의 공헌이다. 推定方法을 지금부터 說明하기로 한다.

各 相異한 諸母集團에서 역시 각각 相異한 標本이 抽出될 것인데 어느 特定標本은 다른 어느 母集團으로부터 보다 더 어느 일정한 母集團으로부터 抽出되었을 可能性이 더 클 것이다. 그래서 이 特定한 標本은 어느 母集團에 속할 可能性이 제일 크나 하는 문제가 제기된다. 이러한 着想에 基準을 둔 推定方法이 곧 最尤法이다. 가령 $\theta_1, \theta_2, \theta_3 \cdots \theta_K$ 라는 母數에 의하여 特徵지어지는 確率分布 $f(x)$ 를 가진 確率變數 X 가 있고 $x_1, x_2, x_3 \cdots x_n$ 등으로 標本을 觀測한다고 하자. 그러면 이 觀測된 標本을 가장 높은 頻度로 抽出했을 母數의 값을 $\theta_1, \theta_2, \theta_3 \cdots \theta_k$ 의 最尤推定量 (maximum likelihood estimators)이라 한다. 最尤推定量은 그 特定한 標本值의 確率 (혹은 確率密度)이 最大가 되게 하는 母數의 값을 말한다. 그래서 最尤推定量을 구하는 것은 곧 $f(x_1, x_2, x_3 \cdots x_n)$ 을 最大로 하는 값을 찾는 것이라고 할 수 있다. 이상은 母數가 K 개 있는 경우였는데 問題의 간략성을 위해 어느 單一母數 θ 하나만을 놓고 보기로 한다. 위의 예에서 그 確率分布 $f(x)$ 는 未知의 母數 θ 에 의하여 特徵지어진다고 하면 X_i 는 相互獨立이기 때문에 標本の 結合確率分布가 다음과 같이 표시될 수 있다.

$$\begin{aligned}
 f(X_1 = x_1, X_2 = x_2, X_3 = x_3, \dots, X_n = x_n) \\
 = f(x_1, x_2, x_3, \dots, x_n) \\
 = f(x_1) f(x_2) f(x_3) \dots f(x_n)
 \end{aligned}$$

이들 各個의 限界確率分布는 母數 θ 에 依存하고 있으므로 이 母數 θ 를 (1)에 포함시키면 다음과 같이 쓸 수 있다.

$$\begin{aligned}
 L(x_1, x_2, x_3, \dots, x_n : \theta) \\
 = f(x_1 : \theta) f(x_2 : \theta) f(x_3 : \theta) \dots f(x_n : \theta)
 \end{aligned}$$

이와같은 標本의 結合確率分布를 θ 의 函數로 看做한 나머지 그 標本에 대한 尤度函數(likelihood function)라 한다.

만약 θ 의 모든 값에 대하여 다음과 같은 관계가 성립되면 $\hat{\theta}$ 는 θ 의 最尤推定量이 된다.

$$L(x_1, x_2, x_3, \dots, x_n : \hat{\theta}) \geq L(x_1, x_2, x_3, \dots, x_n : \theta)$$

예를들어 說明해 보자.

平均 μ 와 分散 σ^2 를 갖고 正規分布를 하고 있는 確率變數 X 가 있다고 하자. 任意標本으로 $\{x_1, x_2, x_3, \dots, x_n\}$ 가 觀測되었다고 할 때 μ 와 σ^2 의 最尤推定値를 구해보면 여기에서 正規確率函數는 다음과 같다.

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

또한 尤度函數는

$$L(x_1, x_2 \dots x_n : \mu, \sigma^2) = \prod_{i=1}^n \left[\left(\frac{1}{2\pi\sigma^2} \right)^{\frac{1}{2}} e^{-\frac{1}{2\sigma^2} (x_i - \mu)^2} \right]$$

$$= \frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2}$$

과 같이 된다. 이것을 代数式으로 變換시키기 위하여 이것에 $\log$ 를 취하면 다음과 같이 된다.

$$\log L = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

이 式에서 μ 와 σ^2 가 未知數이므로 이것들에 대한 一次微分을 求하면 다음과 같이 된다.

$$\frac{\partial (\log L)}{\partial \mu} = \frac{1}{2\sigma^2} \sum_{i=1}^n 2(x_i - \mu) = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu)$$

$$\frac{\partial (\log L)}{\partial \sigma^2} = -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2$$

위의 두 式을 같게 놓아 μ 의 推定量 $\hat{\mu}$ 와 σ^2 의 推定量 $\hat{\sigma}^2$ 를 다음과 같이 誘導할 수 있다.

$$\frac{1}{\hat{\sigma}^2} \sum_{i=1}^n (x_i - \hat{\mu}) = 0$$

$$\sum_{i=1}^n (x_i - \hat{\mu}) = 0$$

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

$$-\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \hat{\mu})^2 = 0$$

$$-n\hat{\sigma}^2 + \sum_{i=1}^n (x_i - \hat{\mu})^2 = 0 \quad (\text{兩項에 } 2\hat{\sigma}^4 \text{ 을 곱하여})$$

$$-n\hat{\sigma}^2 + \sum_{i=1}^n (x_i - \bar{x})^2 = 0 \quad (\bar{x} \text{ 를 } \hat{\mu} \text{ 에 代入})$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$E(\hat{\sigma}^2) = \frac{n-1}{n} \sigma^2$$

위에서 母平均의 推定量은 標本平均과 같으나 分散의 推定量은 標本分散과 같지 않아 不偏이 되지 못한다. 大標本의 경우에는 이 偏倚가 無視될 수 있다. 그래서 小標本인 경우는 수정이 加해져야 한다.

單一方程式 (single equation) 推定에서는 일반적인 方法이 못하고 대부분 最小自乘法이 쓰이므로 간단하게 설명하며는 最尤法은 頻度가 가장 높은 標本觀測을 수반하는 母數를 찾는것이다. 그러므로 標本觀測에 대한 尤度函數 (likelihood function) 을 구하여 이것을 母數에 대하여 極大化해야 한다. Y_i 의 分布를 $Y_i \sim N(E(Y_i), \sigma_y^2)$ 이라 假定한다면 Y_i 는 이러한 平均과 分散을 가지고 각각 獨尤이라 하였다. 그래서 Y_i 標本觀測에 대하여 다음과 같은 尤度函數를 놓을 수 있다.

$$\log L = -\frac{1}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - \hat{a} - \hat{b} X_i)^2$$

단, 平均 $E(Y_i)$ 는 $\hat{a} + \hat{b} X_i$ 로 代入

極大化의 一次條件으로 위 式을 $\hat{a}$, $\hat{b}$ 에 대하여 偏微分하여 0과
같이 놓으면 다음과 같게 된다.

$$\begin{aligned}\frac{\partial \log L}{\partial \hat{a}} &= -\frac{1}{2\sigma^2} \sum_{i=1}^n 2(Y_i - \hat{a} - \hat{b} X_i)(-1) \\ &= \frac{1}{\sigma^2} \sum_{i=1}^n (Y_i - \hat{a} - \hat{b} X_i) = 0\end{aligned}$$

$$\begin{aligned}\frac{\partial \log L}{\partial \hat{b}} &= -\frac{1}{2\sigma^2} \sum_{i=1}^n 2(Y_i - \hat{a} - \hat{b} X_i)(-X_i) \\ &= \frac{1}{\sigma^2} \sum_{i=1}^n X_i (Y_i - \hat{a} - \hat{b} X_i) = 0\end{aligned}$$

이 두 式을 整理하여 다시 쓰면

$$\sum_{i=1}^n Y_i = n \hat{a} + \hat{b} \sum_{i=1}^n X_i$$

$$\sum_{i=1}^n X_i Y_i = \hat{a} \sum_{i=1}^n X_i + \hat{b} \sum_{i=1}^n X_i^2$$

가 된다. 이 두 式은 最小自乘法으로 구한 式과 똑같다. 즉
같은 標本回歸線의 正規方程式이 된다. 이로 미루어 보아 最小自
乘法과 最尤法과는 같은 것이라 할 수 있다. 다만 앞에서 보았
지만 最尤法에서는 標本の 크기가 작으면 分散의 偏倚性이 있는
점과 分散을 推定하기가 더 힘들다는 것이다.

2.3.2 区間推定 (interval estimation)

앞에서 区間推定 (interval estimation) 에 대하여 간단히 설명하였지만 여기서 자세하게 說明하고자 한다. 어느 주어진 確率로 真正한 母數를 包含하고 있을 點推定에 대한 区間을 信賴区間이라 하고 이 信賴区間의 推定을 区間推定이라 한다. 母集團의 平均과 分散에 대한 信賴区間의 推定을 나누어 설명하고자 한다.

(1) μ 의 信賴区間

1) 標準偏差 (σ)를 알고 있을때의 μ 의 信賴区間

한 母集團에서 크기 n 의 任意標本을 抽出하였을 때 n 이 충분히 크면 標本平均 $\bar{x}$ 는 正規分布를 한다고 생각할 수 있으므로 이와같은 사실을 利用하여 母平均 μ 의 区間推定을 하여보자. 그런데 正規分布를 規定하는 母數는 平均 μ 와 標準偏差 σ 이다. 그러므로 標本平均 $\bar{x}$ 를 利用하여 μ 에 대한 確率的인 区間推定을 하려면 母標準偏差 σ 를 알고 있지 않으면 안된다. 그런데 母標準偏差 σ 를 과거의 經驗에서 비교적 正確하게 알고 있다고 믿을 수 있는 경우가 없지는 않지만 대부분 σ 를 알지 못한다. 그러나 여기서는 문제를 간단히 해결하기 위하여 母集團의 σ 를 알고 있다고 생각하기로 한다.

母集團 平均이 μ , 標準偏差가 σ 라고 하면 任意標의 크기 n 이 충분히 클때는 標本平均 $\bar{x}$ 는 平均이 μ 標準偏差가 $\frac{\sigma}{\sqrt{n}}$ 인 正規

分布를 한다. 이것을 標準化 形態로는 다음과 같이 표시 한다.

$$Z = \frac{\bar{X} - \mu}{\sigma / \sqrt{n}}$$

그러면 $P(Z \leq Z_0) = 0.975$

와 같이 되는 Z_0 의 값을 標準正規分布表에서 구하면 $Z_0 = 1.96$ 을 얻는다. 즉

$$P\left(\frac{(\bar{X} - \mu) \sqrt{n}}{\sigma} \leq 1.96\right) = 0.975$$

여기서 괄호안의 부등호를 고쳐 쓰면 $\bar{X} \leq \mu + 1.96 \frac{\sigma}{\sqrt{n}}$ 와 같이 되어

$$P\left(\bar{X} \leq \mu + 1.96 \frac{\sigma}{\sqrt{n}}\right) = 0.975$$

와 같이 된다. 마찬가지로

$$P\left(-1.96 \leq \frac{(\bar{X} - \mu) \sqrt{n}}{\sigma}\right) = 0.025$$

와 같이 되고, 이때도 괄호안을 고쳐 쓰면

$$P\left(\bar{X} \geq \mu - 1.96 \frac{\sigma}{\sqrt{n}}\right) = 0.025$$

와 같이 된다. 결국 위의 두가지 사실을 종합해 보면 $\bar{X}$ 가

$\mu - 1.96 \frac{\sigma}{\sqrt{n}}$ 와 $\mu + 1.96 \frac{\sigma}{\sqrt{n}}$ 사이에 있는 確率, 즉

$$\mu - 1.96 \frac{\sigma}{\sqrt{n}} \leq \bar{X} \leq \mu + 1.96 \frac{\sigma}{\sqrt{n}}$$

와 같이 되는 確率이 95 %로 된다.

이제 위의 左側不等式 $\mu - 1.96 \frac{\sigma}{\sqrt{n}} \leq \bar{X}$ 에서

$$\mu \leq \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}}$$

를 얻고 右側不等式 $\bar{X} \leq \mu + 1.96 \frac{\sigma}{\sqrt{n}}$ 에서

$$\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}} \leq \mu$$

를 얻는다. 이와같이 얻은 두개의 不等式을 한데 모아

$$\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}}$$

와 같이 쓰고 이것을 母平均 μ 에 대한 95 % 信賴區間이라 한다. 마찬가지로 하여 99 % 信賴區間을 구하면 다음과 같이 된다.

$$\bar{X} - 2.58 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + 2.58 \frac{\sigma}{\sqrt{n}}$$

위와같은 信賴區間을 자세히 표현하면 兩側 信賴限界 (two-sided confidence limits) 라고 한다. 이와같이 말하는 理由는 單側 信賴限界 (one-sided confidence limits)를 필요할 때가 있기 때문이다.

標本の 크기가 클때에는 二項母集團에서 比率에 대한 區間推定을 하는데 그대로 應用될 수가 있다. 成功의 母比率 P 를 가지고 있는 二項母集團에서 크기 n 의 標本을 추출하여 成功의 數 r 를 얻었다면 標本比率 $\frac{r}{n}$ 는 P 의 點推定値로 되고, 二項分布 理論에 따라 r 의 期待値는 nP , r 의 分散은 npq 이므로 $\frac{r}{n}$ 의 期待値는 $\frac{nP}{n} = P$, $\frac{r}{n}$ 의 分散은 $\sigma_r^2 = \frac{npq}{n}$ 로 된다. 따라서 n 이 충분히

클 때는 標本比率 $\frac{r}{n}$ 는 平均이 P , 標準偏差가 $\sqrt{\frac{pq}{n}}$ 인 正規分布
를 한다. 그러므로 n 이 충분히 클 때는 다음과 같은 確率公式을 얻
게 된다.

$$P = \left(P - 1.96 \sqrt{\frac{pq}{n}} \leq \frac{r}{n} \leq P + 1.96 \sqrt{\frac{pq}{n}} \right) = 0.95$$

2) σ 를 모를때의 μ 의 信賴區間

위에서는 母平均 μ 를 區間推定하는데 母標準偏差 σ 를 알
고 있다고 하였는데 대부분의 경우 σ 를 알지 못한다. 이와같이
 σ 를 알지 못하는 경우는 標本에서의 觀測值에서 標本標準偏差
 S 를 계산하여 이것에서 母標準偏差 σ 의 推定値로 삼고 σ 대신
에 S 를 사용하여 區間推定을 한다. 標本の 크기가 충분히 클때
사용하는 것이 좋다. 그래서 標本標準偏差 S 를 標準化된 形態인

$$\frac{\bar{X} - \mu}{\sigma / \sqrt{n}}$$

에 σ 대신 代入하여 t -分布를 쓰면

$$\frac{\bar{X} - \mu}{S / \sqrt{n}} \sim t_{n-1}$$

단 t_{n-1} = 自由度 $(n-1)$ 을 가진 t 分布

여기서 다음과 같은 確率을 얘기할 수 있다.

$$P \left(-t_{n-1} : \alpha/2 \leq \frac{\bar{X} - \mu}{S / \sqrt{n}} \leq t_{n-1} : \alpha/2 \right) = 1 - \alpha$$

$(1 - \alpha)$ 는 信賴水準을 가리킨다. 이것을 信賴係數 (confidence

coefficient)의 確率이라고 하는 이도 있다. 윗式을 95 % 信賴水準으로 놓고 보면 $\alpha = 0.05$ 가 되고 윗式은 다음과 같이 쓰여진다.

$$P(-t_{n-1:0.025} \leq \frac{\bar{X} - \mu}{S/\sqrt{n}} \leq t_{n-1:0.025}) = 0.95$$

이것을 다른 形態로 바꾸어 쓰면

$$\bar{X} - t_{n-1:0.025} \frac{S}{\sqrt{n}} \leq \mu \leq \bar{X} + t_{n-1:0.025} \frac{S}{\sqrt{n}}$$

와 같이 된다. t -分布에서 $\alpha = 0.5$ 에 따른 自由度($n-1$)의 값을 가지고 t 값을 찾아 윗式에 代入하면 바로 母平均 μ 에 대한 95 % 信賴區間을 얻게 된다. 99 % 信賴區間도 마찬가지로 얻게 된다.

(2) σ 의 區間推定

이제까지 母集團의 標本에서 母平均 μ 를 區間推定을 하는 것을 說明하였다. 이제 母分散 σ^2 를 區間推定하는 問題를 취급하여 보기로 한다. 만약 母集團이 正規分布에 따른다면 χ^2 -分布表를 이용하여 標本分散 S^2 를 기초로 하여 母分散 σ^2 을 區間推定을 할 수가 있다. σ^2 의 95 % 信賴限界値를 구하기 위하여 $\chi_{0.975}^2$ 와 $\chi_{0.025}^2$ 의 값을 χ^2 -分布表에서 구한다.

$\chi^2 = f S^2 / \sigma^2$ 이므로

$$P(\chi_{0.975}^2 \leq f S^2 / \sigma^2 \leq \chi_{0.025}^2) = 0.95$$

와 같은 관계가 成立하고, 이 관계식에서 다음과 같이 σ^2 의 95 % 信賴區間이 얻어진다.

$$\frac{f s^2}{\chi_{0.025}^2} \leq \sigma^2 \leq \frac{f s^2}{\chi_{0.075}^2}$$

이것이 95 % 信賴區間을 구하기 위한 일반적인 公式이다. 크기 n 의 任意標本에서 S^2 이 계산된 것이라고 하면 $\chi = X - \bar{X}$ 로 하였을 때 $f s^2 = (n-1)S^2 = \sum \chi^2$ 와 같이 되고 式은 다음과 같이 쓸 수가 있다.

$$\frac{\sum \chi^2}{\chi_{0.025}^2} \leq \sigma^2 \leq \frac{\sum \chi^2}{\chi_{0.975}^2}$$

σ 를 좀더 正確히 推定하자면 標本の 크기가 커야된다는 것을 χ^2 -分布表를 살펴 봄으로써 알 수 있다.

2.4 Bayesian 推定方法

2.4.1 Bayes 確率定理

우선 예를 들어 생각해 보자. 흰구슬 (W)이 4개, 빨간구슬 (R)이 6개 들어 있는 상자 A가 3개 있고 흰구슬 (W)이 2개, 빨간구슬 (R)이 8개 들어 있는 상자 B가 7개 있을 때, 任意로 한 상자를 택하여 구슬 하나를 抽出하였을 경우 그것이 상자 A에서 흰구슬이 抽出될 確率이 얼마인가를 생각해 보자. 이번에는 만 사람에게 의하여 위와 같은 抽出作業이

실시되고 최종적으로 抽出된 것이 흰구슬 (W) 이었다는 것만을 알고, 이것이 A 상자에서 抽出되었을 確率이 얼마인가를 물어 봤을 때 이에 대한 대답은 어떻게 될 것인가? 이때에는

$$P(A|W)$$

를 구하는 問題로 된다.

$$P(A|W) = \frac{P(A, W)}{P(W)}$$

$$\text{이고, } P(W) = P(A, W) + P(B, W)$$

$$P(A, W) = P(A) P(W|A),$$

$$P(B, W) = P(B) P(W|B)$$

이므로 위식은 다음과 같이 된다.

$$P(A|W) = \frac{P(A)P(W|A)}{P(A)P(W|A) + P(B)P(W|B)}$$

위의 例의 경우는 $P(W|A) = 0.4$, $P(A) = 0.3$, $P(W|B) = 0.2$, $P(B) = 0.7$ 이므로

$$P(A|W) = \frac{(0.3)(0.4)}{(0.3)(0.4) + (0.7)(0.2)} = \frac{12}{36}$$

와 같이 質問에 대한 답을 얻는다.

일반적으로 서로 排反적이고 集合적으로 망라된 事件 $A_1, A_2 \dots A_n$ 이 있고 이와같은 事件의 하나가 일어나는 것이 다른 한 事件 B가 일어나는데 필요한 前提條件으로 될때 確率 $P(A_i|B)$ 는 다음과 같게 된다.

$$P(A_i|B) = \frac{P(A_i)P(B|A_i)}{P(A_1)P(B|A_1) + P(A_2)P(B|A_2) \cdots P(A_n)P(B|A_n)}$$

이것이 Bayes 確率定理라고 한다. 그리고 이것은 英國의 Thomas Bayes 의 이름을 따서 命名된 定理이다. 이와 같이 계산된 確率을 事後確率 (posterior probability) 이라고 하며, 근래 소위 不確定的 狀況下에서의 意思決定問題에 많이 이용되고 있다. 여기에서 Bayes 定理의 직접적인 應用例를 들어 보자.

어느 地方의 한 群內 全体住民의 1%가 어느 특정한 病에 걸려 있다. 그런데 이 病에 대한 감염여부를 알아보는 새로운 진단방법에 의하면 이 病에 감염되어 있는 사람들의 97%가 (+) 反應을 나머지 3%가 (-) 反應을 나타낸다. 한편 감염되어 있지 않은 사람들도 그들중 5%가 (+) 反應을 나타내고 95%가 (-) 反應을 나타낸다고 한다. 지금 住民중에서 한 사람을 任意로 抽出하여 이 病에 대한 검진을 하여 본 결과 (+) 反應을 나타냈다고 한다. 그러면 이 사람이 이 病에 감염되어 있을 確率は 얼마인가?

病에 감염되어 있다는 事件을 D, 감염되어 있지 않다는 事件을 N로 표시한다면 위에서 설명한 바는

$$P(D) = 0.01, P(N) = 0.99 \text{ 이고}$$

$$P(+|D) = 0.97, P(-|N) = 0.95$$

$$\text{따라서 } P(-|D) = 0.03, P(+|N) = 0.05$$

와 같게 된다. 따라서 구하는 답은 Bayes 定理에 의하여

$$\begin{aligned}
 P(D|+) &= \frac{P(D) P(+|D)}{P(D) P(+|D) + P(N) P(+|N)} \\
 &= \frac{(0.01)(0.97)}{(0.01)(0.97) + (0.99)(0.05)} \\
 &= 0.16
 \end{aligned}$$

과 같게 된다. 그러므로 $P(N|+) = 0.84$ 이것은 病에 걸려 있는 사람의 97%가 검진결과 (+) 反應을 나타내는 데도 불구하고 검진결과 (+) 反應을 나타낸 사람 중 16%만이 정말로 病에 걸려 있을 것이라는 데 놀라지 않을 수 없다. 그런데 만일 任意로 抽出된 사람이 검진결과 (-) 反應을 나타냈다고 하면, 어떻게 될 것인가? 이 경우는

$$\begin{aligned}
 P(D|-) &= \frac{P(D) P(-|D)}{P(D) P(-|D) + P(N) P(-|N)} \\
 &= \frac{(0.01)(0.03)}{(0.01)(0.03) + (0.99)(0.95)} \\
 &= 0.00032
 \end{aligned}$$

$$P(N|-) = 1 - 0.00032 = 0.99968$$

과 같이 되어 (-) 反應을 보인 사람은 거의 틀림없이 건강하다는 것을 알 수 있다. 다시 말하면 (-) 反應을 보일 때는 상당히 正確하게 판단을 내릴 수 있다. 그런데 만약 위와같은 검진방법에 의하면 (+) 反應을 보이면 항상 病에 감염되어 있는 것으로 판단을 내리고 (-) 反應을 보일 때는 언제나 病에 감염되어 있지 않다는 것으로 판정을 내리기로 한다면 이와같은 判定決定方法이

적중될 確率は 얼마나 될까 생각해 보면 옳은 判定을 내릴 確率

$$= P(D, +) + P(N, -)$$

$$= P(D) P(+ | D) + P(N) P(- | N)$$

$$= (0.01) (0.97) + (0.99) (0.95)$$

$$= 0.0097 + 0.9405 = 0.9502$$

와 같이 되어 判定이 적중될 確率が 95 %나 된다는 결론을 얻는다. 이와 같이 確率값이 큰 것은 (-) 反應을 보이고 病에 감염되어 있지 않은 사람의 確率が 94.05 %인 것에 기인한다.

실제로 病에 감염되어 있고 (+) 反應을 보이고 住民은 全体住民의 겨우 0.97 %이고, 病에 감염되어 있지 않고 (+) 反應을 보이는 住民은 全体住民의 $P(N, +) \times 100 \% = 4.95 \%$ 로서, 人口比例로 보아 後者が 前者의 5 배가 된다. 그러므로 任意로 한 사람을 抽出하였을 때 病에 감염되고 (+) 反應을 보이는 사람보다 病에 감염되어 있지 않고 (+) 反應을 보이는 사람이 5 배나 더 잘 抽出될 可能性이 있다는 事實에서 $P(N | +) = 0.84$ 과 같은 計算이 나오지만, 이와 같이 오진의 原因으로 되는 사람을 검진하게 될 기회가 드물다는 것을 이해하면 옳게 판단을 내리게 되는 確率が 95 %나 된다는 것이 이상하지 않을 것이다.

2.4.2 事前分布와 事後分布

(1) 事前分析 (事前分布)

實際적인 意思決定問題에 있어서는 意思決定者가 여러가지

可能한 自然의 狀態(事件)에 대하여 그 各 狀態가 실현될 수 있는 可能性의 정도에 대하여 어떤 豫測이 있을 것이고 이것이 意思決定에 도움을 줄 것이라고 생각하는 것은 合理的인 것이라고 할 수 있다. 예를 들어 說明하면 P氏는 어떤 것을 발명하여 特許를 얻었다. 銀行은 이것을 企業化하는데 資金을 제공할 것을 이미 약속했다. 한편 조사연구결과 앞으로 5년간은 이 발명으로 利得을 알아 보는데 적당한 期間이라는 것을 알았다. 그의 調査結果에 의하면 만약 製品이 아주 잘 팔리면 앞으로 5년간 ₩800,000,000의 利得이 있고 보통으로 팔리면 ₩200,000,000의 利得이 있으며 보통이하로 팔리면 ₩50,000,000의 損失이 있게 된다. 한편 어느 大企業에서 이 特許權을 사들일 것을 제안하여 왔다. 이 제안은 잘 팔릴 경우 ₩400,000,000의 配當을 받고 보통으로 팔릴때는 ₩70,000,000을 보통 이하로 팔릴 때는 ₩10,000,000를 배당받게 된다. 이것을 表로 작성하면 아래와 같다.

事 件	행 위	
	A ₁ : 기업을 자신이 한다.	A ₂ : 特許權을 판다.
θ_1 : 아주 잘 팔린다.	₩ 800,000	400,000
θ_2 : 보통으로 팔린다.	200,000	70,000
θ_3 : 보통이하로 팔린다.	-50,000	10,000

또 各 自然의 狀態가 일어날 수 있는 可能性의 程度 즉 確率이 다음과 같다고 하자 이와같은 確率을 事前確率 (prior probability) 이라고 한다.

自然의 狀態 (事件)	確 率 $P (\theta_i)$
θ_1 : 아주 잘 팔린다.	0.2
θ_2 : 보통으로 팔린다.	0.5
θ_3 : 잘 팔리지 않는다.	0.3

그러면 行為 A_1 에 대한

$$\begin{aligned} \text{期待金額值} &= (0.2) (\text{₩ } 800,000,000) + (0.5) (\text{₩ } 200,000,000) \\ &\quad + (0.3) (- \text{₩ } 50,000,000) \\ &= \text{₩ } 245,000,000 \end{aligned}$$

行為 A_2 에 대한

$$\begin{aligned} \text{期待金額值} &= (0.2) (\text{₩ } 400,000,000) \\ &\quad + (0.5) (\text{₩ } 70,000,000) + (0.3) (\text{₩ } 10,000,000) \\ &= \text{₩ } 118,000,000 \end{aligned}$$

와 같이 된다. 이와같은 期待金額值에 기준을 둔다면 行為 A_1 즉 자기가 직접 제품을 생산하기로 결정하게 될 것이다. 이와같이 自然의 狀態에 관한 事前情報를 이용하는 意思決定 分析方法을 事前分析 (prior analysis) 法이라 한다.

不確定的 狀況下에서 意思決定을 하는데 있어서 유용한 概念으로 機會損失 (opportunity loss) 이라는 것이다. 機會損失이라 하는

것은 實際狀況에 対応하여 最適의 行위를 취하지 못했기 때문에 생기는 損失을 의미한다. 위에 있는 예에서 실제의 自然狀態가 θ_1 이라고 할 때 행위 A_1 를 택하였다면 이것이 最適의 행위이므로 이때의 機會損失은 ₩ 0 으로 되지만 이때에 행위 A_2 를 택하였다면 機會損失은 ₩ 800,000,000 - ₩ 400,000,000 = ₩ 400,000,000 으로 된다. 한편 실제 自然의 狀態가 θ_3 일때 행위 A_1 을 택하였다면 機會損失은 ₩ 10,000,000 - (₩ -50,000,000) = ₩ 60,000,000 으로 되고 행위 A_2 를 택하였다면 ₩ 0 으로 된다. 이와같은 것을 表로 작성하면 아래와 같다. 機會損失은 항상 正의 數로 表示되는 것이며 단순히 損失(loss)이라 한다.

自然의 狀態	利 得 表		機 會 損 失 表	
	A_1	A_2	A_1	A_2
θ_1	₩ 800,000	₩ 400,000	₩ 0	₩ 400,000
θ_2	200,000	70,000	0	130,000
θ_3	- 50,000	10,000	60,000	0

이와같은 期待機會損失値를 기준으로 하여도 역시 행위 A_1 를 택하는 것이 유리하다. 이와같이 意思決定에 利得에 관한 期待金額値를 使用하거나 또는 損失에 관한 期待値를 使用하거나 최종적으로 意思決定을 하는데 있어서 다를 것이 없다는 것을 알 수 있다. 그런데 機會損失이 期待値를 計算하지 않고 그보다는 하나 하나의 機會損失 그 自体에 관심을 갖는 사람이 있다. 이와같은 方法은 어떤 행위에 있어서 일어날 수 있는 가장 큰 損失이 때

로는 치명적인 재기불능의 損失을 가져올 수 있기 때문이다. 행위 A_1 을 갖을때 最大機會損失値는 ₩60,000,000 이고 행위 A_2 는 ₩400,000,000 이다, 따라서 可能한 비극적인 最大損失이 最小인 행위는 A_1 이라 할 수 있고 이와같이 각 행위에 따르는 最大損失値中에서 最小인 값 ₩60,000,000 을 Minimax機會損失値라고 한다. 이러한 Minimax機會損失値를 기준으로 하여 意思決定을 하는 것을 Minimax意思決定法이라 한다.

2) 事後分布 (事後分析)

앞에서 事前確率에 依存하여 어떤 행위에 대한 期待利得을 구하여 意思決定을 하는 方法을 설명하였으나, 여기서는 事前情報 즉 事件이 일어 나는데 대한 事前確率을 이용할 뿐 아니라, 標本抽出 또는 實驗을 통하여 얻는 추가적인 情報를 이용하여 각 事件에 대한 事後確率 (posterior probability) 을 구하고 이것에 의하여 事後期待利得을 구하여 意思決定을 하는 方法을 설명하고자 한다. 이와 같은 方法을 事後分析 (posterior analysis法)이라 하고 이때에 確率論에서의 Bayes公式을 이용하게 된다. 앞에서 發明特許品の 例를 이용하여 설명한다면 우선 發明한 새로운 製品을 試作하여 이에 대한 試驗販売를 하여 市場調査를 하여 본다. 그리고 調査結果를 아주 잘 팔리면 x_1 으로, 보통으로 팔리면 x_2 로 잘 안팔리면 x_3 로 表示하기로 한다. 지금 실제 市場調査結果 보통으로 팔려서 x_2 라고 하는 結果를 얻었다 하자. 그런데 이와

같은 결과는 어디까지나 試驗調查結果이므로 自然의 狀態를 그대로 반영하고 있다고는 말할 수 없다. 즉 참 상태가 θ_1 일 때에도 調查結果 x_2 로 되는 일은 있을 수 있는 것이다. 지금 어떻게 되는 確率이 0.1 즉 $P(x_2 | \theta_1) = 0.1$, 마찬가지로 眞狀態가 θ_2 일때 x_2 로 되는 確率 $P(x_2 | \theta_2) = 0.8$, 眞狀態가 θ_3 일때 x_2 로 되는 確率 $P(x_2 | \theta_3) = 0.2$ 와 같다고 하자. 이와같이 特定한 θ_i 를 條件으로 하고 이 條件下에서 實驗이나 標本抽出에 의하여 어떤 結果를 얻게 되는 確率을 尤度 (likelihood)라고 한다. 그리고 이러한 尤度 (條件附確率)는 事前確率과 實驗이나 標本抽出結果에서 이론적으로 구해질 수 있는 경우가 많다.

그러면 Bayes 公式

$$P(\theta_i | x_2) = \frac{P(\theta_i) P(x_2 | \theta_i)}{P(\theta_1)P(x_2 | \theta_1) + P(\theta_2)P(x_2 | \theta_2) + P(\theta_3)P(x_2 | \theta_3)}$$

를 이용하여 다음과 같이 事後確率을 구해진다.

事後確率의 計算

事 件	事前確率 $P_0(\theta_i)$	尤 度 $P(x_2 \theta_i)$	結合確率 $P_0(\theta_i)P(x_2 \theta_i)$	事後確率 $P_1(\theta_i) = P(\theta_i x_2)$
θ_1	0.2	0.1	0.02	0.042
θ_2	0.5	0.8	0.40	0.833
θ_3	0.3	0.2	0.06	0.125
計	1.0		0.48	1.000

여기에서 事後確率은 $P_1(\theta_1) = \frac{0.02}{0.48} = 0.042$

$$P_1(\theta_2) = \frac{0.40}{0.48} = 0.833.$$

行為 A₁ 에 대한 事後期待利得과 事後期待損失

(単位 : ₩ 1,000)

事 件	事後確率 $P_1(\theta_i)$	利 得	損 失	期待利得	期待損失
θ_1	0.042	₩ 800,000	₩ 0	₩ 33,600	₩ 0
θ_2	0.833	200,000	0	166,600	0
θ_3	0.125	- 50,000	60,000	- 6,250	7,500
	1.000			₩ 193,950	₩ 7,500

$P_1(\theta_3) = \frac{0.06}{0.48} = 0.125$ 와 같이 구한 것이다. 이와같이 事後確率을 구하면 이것을 利用하여 각 행위에 대한 事後期待利得, 事後期待損失등을 다음과 같이 계산할 수가 있다.

行為 A₂ 에 대한 事後期待利得, 事後期待損失

(単位 : ₩ 1,000)

事 件	事後確率 $P_1(\theta_i)$	利 得	損 失	期待利得	期待損失
θ_1	0.042	₩ 400,000	₩ 400,000	₩ 16,800	₩ 16,800
θ_2	0.833	70,000	130,000	58,310	108,160
θ_3	0.125	10,000	0	1,250	0
	1.000			₩ 76,360	₩ 124,960

따라서 행위 A_2 에 대한 事後期待利得은 ₩ 76,360,000, 事後期待損失은 ₩ 124,960,000과 같게 된다.

2.4.3 Bayesian推定

古典的인 推定方法과 비교하여 說明하고자 한다. 古典的인 統計的 方法에서는 母集團比率 P 를 推定하는데 標本比率 $\hat{P}$ 를 使用한다. 그리고 Bayesian 統計的 方法에서는 推定을 自然의 狀態 P 에 대한 하나의 행위로서 규정한다. 또 P 가 未知인 경우에는 이것을 하나의 確率變數로 취급한다.

推定하고자 하는 母數의 값을 θ 라고 하고 $\hat{\theta}$ 를 母數 θ 의 推定値라고 하자. 그러면 $\hat{\theta}$ 가 θ 와 一致하지 않는 것에서 생기는 損失을 생각할 수가 있을 것이다. 이와같은 損失을 $(\hat{\theta} - \theta)$ 의 함수로서 정의하는 것이 보통이다. 例를 들면

$$L(\hat{\theta} : \theta) = |\hat{\theta} - \theta|$$

또는

$$L(\hat{\theta} : \theta) = (\hat{\theta} - \theta)^2$$

여기에서 $L(\hat{\theta} : \theta)$ 는 損失函數를 표시하는 記号이고, 특히 두번 제와 같이 정의한 損失函數를 平方誤差損失函數(squared error loss function)라고 한다.

Bayesian 統計學者는 우선 $\hat{\theta}$ 의 모든 可能한 값에 대하여 損失函數의 期待値를 구한다. 이와같이 구한 損失函數의 期待値는 주어진 θ 에 대한 條件附, 期待損失値라고 할 수 있으며 이것을

특히 危險値 (Risk) 라고 한다. 여기에서 母數 θ 가 未知일 때는 θ 를 確率變數로 생각하기 때문에 위에 구한 危險値는 θ 에 관한 危險函數 (risk function) 라고 생각할 수 있게 된다. 지금 θ 의 모든 可能한 값에 대하여 事前確率 $P(\theta)$ 가 주어졌다고 생각을 하자. 그러면 이 事前確率을 이용하여 危險値의 期待値를 구할 수 있다. 이것을 Bayes 危險値 (Bayes risk) 라고 한다. 그런데 이와 같은 Bayes 危險値는 θ 를 推定하는 方法에 따라 그 값을 달리한다. 모든 推定方法중에서 Bayes 危險値를 最小로 하는 推定方法이 있다면 이것이 Bayes 推定方法으로 된다.

지금 한 동전의 表面出現 比率 P 를 推定하는 문제를 생각한다. n 회 동전을 던져서 r 회 表面이 나왔다면 古典的인 統計的方法에는 P 의 推定値로서 標本比率

$$\hat{P} = \frac{r}{n}$$

를 택한다. 그러나 Bayesian 統計學者는 $L(\hat{P} : P) = (\hat{P} - P)^2$ 와 같은 損失函數를 생각하고, P 가 0 과 1 사이에 均一하게 分布 (이것을 直四角形分布라고 한다.) 되어 있다는 事前確率分布를 부여하여 Bayes 推定方法으로서

$$\hat{P} = \frac{r+1}{n+2}$$

를 얻는다. 여기에서 주목할 만한 것은 n 값이 클때는 두가지 方法은 결국 一致한다는 事實이다. 그러나 Bayesian 方法에서는

損失函數로서 무엇을 정의하여 사용하느냐 또 事前確率分布를 어떻게 부여하느냐에 따라서 推定方法이 달라진다. 그런데 古典的인 統計學者는 무엇보다도 事前確率分布를 부여하는 그 근거에 대하여 그 不合理性을 문제로 삼는다. 사실 이 점에 대해서는 Bayesian 統計學을 신봉하는 사람들도 確信을 가지고 自己主張을 내세울 수 없는 때가 많다. 지금까지는 點推定에 관해서 說明했으나 다음부터는 區間推定에 관해서 說明하기로 한다.

古典的인 統計學理論에 의하면 이와 같은 區間推定에 있어서 母比率 P 를 그 區間에 包含하는 確率은 95 %라는 것을 意味한다고 해석하는 것은 잘못이라고 경고하고 있다. 區間推定이 意味하는 것은 區間推定을 되풀이 해서 하면 이와같은 區間이 母數를 包含하게 되는 確率은 95 %라는 것이다. 사실 古典的인 統計學에서는 母數는 어느 特定常數이고 따라서 統計量(推定值)을 條件으로 한 母數 P 의 條件附確率같은 것은 생각할 수 없는 것으로 되어 있다. 즉 $P(P|\hat{P})$ 와 같은 것은 생각할 수 없는 것이고 오직 $P(P|\hat{P})$ 만을 생각할 수 있는 것으로 되어 있다.

그러나 Bayesian 統計的 方法은 이와같은 古典的인 方法과는 아주 대조적이다. 母比率 P 가 未知일 때는 P 를 하나의 確率變數로 취급한다. 그러므로 $P(P|\hat{P})$ 와 같은 條件附確率을 서슴치 않고 사용한다. 따라서 P 의 事前確率 $P_0(P)$ 가 주어지면 標本에서 얻은 情報를 기초로 하여 P 의 事後確率 $P_1(P)$ 를 Bayes 公式에

의하여 구할 수 있게 된다. 이와같이 P 의 事後分布가 결정되면 確率變數 P 를 포함하는 區間, 例를 들면 95% 信賴區間을 구하는 것은 어렵지 않을 것이며 이것이 古典的인 統計的 方法에 있어서의 信賴區間에 対応하는 것으로 될 것이다. 그런데 재미있는 것은 點推定에 있어서 標本의 크기 n 이 대단히 클때는 P 가 0과 1 사이에서 均一하게 分布한다는 事前確率分布를 부여할 때 古典的推定方法과 Bayesian 推定方法과는 一致하여 差異가 없다는 것을 알았는데 이러한 관계는 區間推定の 경우에도 성립한다. 그런데 P 에 대하여 직사각형분포(均一分布)를 事前確率分布로서 생각하는 것은 P 에 대한 어떤 특별한 知識이 없다는 것을 意味하는 것이라 생각할 수 있으므로 이것은 바꾸어 말하면 古典的인 點推定이나 區間推定の 方法은 母數에 대한 合理的인 可能性을 고려하고 있다고는 할 수 없다는 비난을 Bayesian 統計學者들로부터 받게 되는 것이다.

以上에서 論議한 것에서 짐작할 수 있는 바와 같이 古典的인 統計學者와 Bayesian 統計學者들 사이에는 많은 論爭이 계속되어 왔고 사용하는 用語도 다르지만 이들 學者들은 다같이 대상으로 하고 있는 自然의 狀態에 관한 정보를 수집하기 위하여 標本抽出이나 實驗을 하고 이것을 기초로 하여 행위를 決定하는 것과 같은 方法으로 意思決定 問題를 해결하려고 하고 있다. 이 두系統의 學者들은 다같이 意思決定過程에서 주어진 自然의 狀態에 대한

標本抽出結果의 條件附確率을 계산한다.

古典的인 統計學者들은 이것을 기초로 하여 意思決定에 따르는 제 1종의 과오 또는 제 2종의 과오의 심각성을 따지게 된다. 그러나 이와 같은 것이 具體적으로 어떻게 決定되어야 하는가에 대하여서는 明確하게 가르쳐 주는 것이 없다. Bayesian 統計學者들은 自然의 狀態에 대한 主觀的(經驗的)인 事前確率을 부여하고 意思決定에 따르는 과오를 나타내는 損失函數를 준비하여 古典的인 의 사결정절차를 補完 또는 完成하려는 立場을 취한다고 할 수가 있다. 그러나 이와같은 경우 事前確率과 損失函數가 새로이 論議의 対象으로 제기된다고 할 수가 있다.

古典的 統計學者와 Bayesian 統計學者들간에 있어서 중요한 差異點은 事前確率分布를 생각하느냐 안하느냐 하는 点이라고 할 수가 있다. 古典的 統計學者들은 客觀的인 確率 또는 相對頻度만이 생각할 수 있는 合理的인 것이라 주장한다. 그들은 主觀的 또는 個人的인 確率이 Bayes 公式을 이용하여 事後確率을 계산하는데 사용된다는 点이 理解하기 어렵다는 것이다. 그러나 Bayesian 統計學者들은 實際적으로 어떤 문제에 대하여 意思決定을 하는 경우 이미 설명한 바와 같은 Bayesian的 사고의 과정을 거쳐서 하는 것이라고 주장한다. 특히 오직 客觀的인

確率만을 이용해야 된다는 견해를 고수한다면 經營이나 經濟的인 문제와 관련된 어떤 意思決定問題를 해결하기 어렵다고 주장한다. 그런데 어떻게 事前確率을 부여하느냐 하는 것은 실제로 어려운 問題로서 Bayesian 統計的 方法을 신봉하는 사람들도 이 점에 대하여서는 確信이 없는 것이 보통이다. 결국 古典的인 方法과 Bayesian 統計的 方法에 대한 것을 한마디로 비판하고 비교한다는 것은 쉬운 일이 아니다.

第 3 章 統計的 檢定

이 章에서는 不確定성이 介在되어 있는 一部情報에 의하여 合理的인 意思決定을 어떻게 하느냐 하는 것을 다루게 된다. 不確定性を 다루는 데는 이미 알고있는 여러가지 統計量의 確率分布를 活用하게 될 것이다. 第2節에서는 소위 古典的인 統計的 假說檢定(statistical testing hypothesis) 方法을 說明하고, 第3節에서는 어떤 統計量의 確率分布를 假定하기 어려운 경우에 適用될 수 있는 非母數的 方法(Non-parametric method)을 다루었으며, 또한 假說檢定에 관한 理論은 하나의 意思決定에 관한 것이라고 할 수가 있다. 그러나 이와같은 假說檢定에 관한 理論(이것을 傳統的, 古典的 意思決定 方法이라고도 한다)만으로는 實際的인 問題解決에 充分하지 못한 때가 많다. 그러므로 近來에 와서 特別히 過去 20餘年間 事業經營, 産業管理, 또는 行政管理上의 意思決定을 돕고 向上시키는데에 必要한 確率과 統計的方法이 크게 要求되어 이와 같은 分野에서 應用되는 統計理論과 方法인 Bayesian 意思決定論(Bayesian decision theory)을 마지막 節에 취급하였다.

3.1 假說檢定이란?

統計的 決定(statistical decision)을 내리기 위한 方法에서 比較的 單純하게 使用되는 것이 統計的 假說檢定임을 이미 앞

에서 言及한 바 있지만 이와 같은 統計的 假說을 設定하는데 있어서는 다음의 例에 의하여 說明하여 보기로 하자.

即, A都市의 T·V 所有世帶 가운데 任意로 300世帶만을 抽出하여 調査한 結果 金公團用 T·V를 가진 世帶가 125이고 電子用 T·V를 가진 世帶가 175라고 하면 이 事實으로써 「A都市의 T·V 所有世帶가운데 半數 以上이 電子用 T·V를 가지고 있다」라고 말할 수 있을 것인가? 여기에서 調査對象을 300世帶에서 1,000 또는 2,000世帶로 增加시킨다면 그 結果에 대하여도 電子用 T·V가 半數 以上이다. 라고 決定할 수 있을 것인가 하는 問題가 發生한다.

이러한 경우 電子用 T·V가 $1/2$ 以上이라는 假說을 세우게 되며 이것을 歸無假說(Null hypothesis)이라고 하여 H_0 로 表示하는 것이 普通이며 이에 대하여 標本의 數를 增加시킴에 따라 反對로 金公團用 T·V가 그 差를 좁혀 나아갈지도 모르기 때문에 여기에서도 하나의 假說로서의 對立假說(Alternative hypothesis)을 생각할 수 있으며 H_1 으로 表示하는 것이 普通이다.

따라서 統計的 假說檢定은 다음 중 하나에 대하여 옳다는 判斷을 내리게 될 것이다.

- (1) A都市의 T·V의 所有世帶 가운데 $1/2$ 以上이 電子用 T·V를 所有하고 있다.
- (2) A都市의 T·V 所有世帶 가운데 金公團用 T·V를 所有하고 있는 世帶도 $1/2$ 이 된다.

即 (1) 은 帰無仮説 H_0 를 受落하게 되는 경우이고 (2)는 帰無仮説을 棄却하고 対立仮説 H_1 을 採択하는 경우가 되는 것이다.

앞에서 알한바와 같이 統計的 仮説檢定은 母集團에서 n 個의 標本 $x_1, x_2, \dots, x_n$ 을 基礎로 하여 H_0 와 H_1 의 어느쪽을 採択할 것인가에 있다. 그러므로 標本の 確率分布와 統計量을 適当히 取하게 되면 이와 같은 問題를 解決할 수가 있다.

예를 들어 A都市의 T·V 所有台數의 경우 個別事象의 出現確率이 0.5 이고 $n = 300$ 인 標本集團에서 電子用 T·V (하나의 事象)가 175 회 以上 나타날 수 있는 確率이 얼마인가를 求하는 것과 같으므로 正規分布의 平均과 分散을 利用하여

$$\mu = nP = 300 \times 0.5 = 150$$

$$\sigma = \sqrt{npq} = \sqrt{300 \times 0.5 \times 0.5} = 8.66$$

을 計算하고 이것을 面積으로 換算하여 보면

$$Z = \frac{\bar{x} - \mu}{\sigma} = \frac{175 - 150}{8.66} = 2.9$$

가 되므로 數值表에서 얻은 $2.9 = 0.4981$ 을 가지고 $0.5 - 0.4981 = 0.0019$ 가 計算되는 바 電子用 T·V를 所有한 世帯가 175 世帯를 초과하는 것은 500 회에 1회의 比率을 차지하게 되는 것을 알 수 있다. 그러나 이와 같은 偶然的인 現象인 $P=1$ 의 統計的 仮説이 正確하지 못하다고 본다면 이 仮説은 棄却하게 되며 反對로 正確하다고 보면 仮説을 採択하게 되는 것이다.

다시 말하면 이와 같은 判斷(意思決定)들은 어디까지나 수집된 統計資料의 分析에 의해서 내려지는 것이기 때문에 어느쪽으로 決定이 내리든 간에 거기에는 過誤(잘못)을 저지르게 될 可能性이 항상 있다. 따라서 옳은 假說을 棄却함으로써 나타나는 過誤를 第1種의 過誤(error of the first kind, or type I error)라 하며 棄却하여야 할 假說을 取하게 되는 過誤를 第2種의 過誤(error of the second kind, or type II error)라고 한다. 이와 같은 假說의 採択과 棄却과 이에 따르는 過誤와의 關係를 表示하면 아래 표와 같다.

표 .3.1.1

行 為	自然의 狀態	
	H_0 가 眞임	H_1 이 眞임
H_0 를 受落	옳은 意思決定	第2種의 過誤
H_0 를 棄却	第1種의 過誤	옳은 意思決定

여기에서 第1種의 過誤를 저지르는 確率을 危險率(risk ratio) 또는 有意水準(significant level)이라하며 假說檢定에 있어서의 判斷의 基準으로 삼고있는 것이 普通이다.

이 有意水準의 값으로는 5% 또는 1%로 말하는 것이 보통이다. 그런데 이 有意水準을 작게하면 第2種의 過誤가 커지는 경향이 있다.

또한 標本에서 求하여진 實測値의 判定基準에 따라 假說을 取하

거나 棄却하게 되는데 이때 棄却하는 領域을 棄却域 (critical region) 이라고 하여 다음의 그림 3.1.1 의 斜線部分에 해당한다.

一般的으로 Neyman - Pearson 流의 檢定은 標本の 數 n 과 有意水準 α 를 주어진 것으로 하는 가운데 第2種의 過誤로 β 가 最小가 되게 하는 方法을 使用하고 있는 바 正規母集團을 構成하는 特性值를

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad \sigma^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

이라고 하면 統計量 T 는

$$T = \frac{\bar{X} - \mu}{\sigma / \sqrt{n-1}}$$

로 表現되며 $100\alpha\%$ 點을 t_0 라 할 때

$|t| > t_0$ 이면 H_0 를 棄却하고

$|t| < t_0$ 이면 H_0 를 採択하게

된다.

이와 같은 檢定法에서는 一般的으로 片側檢定 (one tail-test) 과 兩側檢定 (two tail - test) 을 取하고 있으며 有意水準 α 가 주어진 경우

$$\left. \begin{aligned} P(t > t_0) &= \alpha \\ P(t < t_1) &= \alpha \end{aligned} \right\}$$

는 片側檢定 (one tail-test) 을 나타내며

$$P(t > t_2) = P(t < t_1) = \frac{\alpha}{2}$$

는 兩側檢定을 表示한다.




그림 3.1.1

그러므로 有意水準 5%인 경우의 右片側檢定에서는

$t \geq 1.645$ 이면 H_0 를 棄却하고

$t < 1.645$ 이면 H_0 를 採択하며

左片側檢定에서는

$t \leq -1.645$ 이면 H_0 를 棄却하고

$t > -1.645$ 이면 H_0 를 採択된다.

또한 兩側檢定에 있어서는

$t > 1.96$ 과 $t < -1.96$ 이면 H_0 를 棄却하고,

$-1.96 < t < 1.96$ 이면 H_0 를 採択하게 된다.

3.2 母数 検定

(1) 平均의 検定

平均의 検定이란 母平均이 주어진 값 μ 와 같은가 그렇지 않은가를 検定하는 것이다. 例를들어 서울特別市 中区에 居住하는 住民 100 名을 選出하여 나이를 調査한 結果 平均 나이가 30 세인 경우, 서울 特別市 全體 市民의 平均나이가 30 세라고 할 수 있을 것인가 하는 問題가 제기 되었을 때 간단히 肯定할 수는 없는 것이다. 이것은 母集團과 標本사이에 發生하는 誤差로 하여 母平均과 標本平均이 같을 수도 있으나 다를 수도 있기 때문이다.

(A) 大標本인 경우

任意로 抽出한 10 名의 學生에 대한 平均身長이 164 cm 이다. 이것으로 全國學生의 平均身長이 162 cm 보다 크다고 할 수 있을 것이다.

이 때의 標準偏差를 5 cm 라고 하면 母平均이 162 cm 이고 確率比率이 $\sigma / \sqrt{n} = 5 / \sqrt{100} = 0.5$ 인 正規分布가 되므로 이를 t 로 變換

$$t = \frac{\bar{x} - \mu}{\sigma / \sqrt{n}} = \frac{164 - 162}{0.5} = 4$$

를 얻는다. 이 값의 確率は 0.0002 가 되어 標本平均 164 cm 의 學生을 $\mu = 162$ cm 이고 $\sigma = 5$ cm 인 母集團에서 抽出한다는 假說은 棄却되며 100 名의 學生에 대한 平均身長은 全國의 平均身長보다

크다는 것을 알 수 있다.

一般的으로 母平均 μ 와 分類 σ^2 이 얻어지고 n 이 큰 경우에는 有意水準 1%에서는 標準偏差 σ 의 2.58 배보다. 큰 경우가 假說은 棄却되는 것이다.

即 $P\{|\bar{x}-\mu| > 2.58 \sigma/\sqrt{n}\} = 0.01$ 이 되므로

① $|\bar{x}-\mu| > 2.58 \sigma/\sqrt{n}$ 인 경우에는 H_0 는 棄却되고

② $|\bar{x}-\mu| \leq 2.58 \sigma/\sqrt{n}$ 인 경우에는 H_0 는 採択된다.

(B) 小標本인 경우

위의 例를 그대로 利用하여 任意로 抽出한 學生을 10名으로 하고 分散 $25 cm^2$ 에 대하여 檢定하면 小標本인 場合의 檢定을 說明할 수 있다.

即 이 標本の 確率分布는 $n < 30$ 이므로 正規分布를 이루지 못하는데 母分散이 알려져 있지 않기 때문에 σ 에 代值하여 標本 標準偏差 S 를 利用하면

$$t = \frac{\bar{x} - \mu}{S/\sqrt{n}} \quad S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

를 얻을 수 있으나 確率變數 t 는 標準正規分布를 하지 않을 뿐 아니라 n 에 따라서 그 分布狀態가 달라진다는 것이 W.S.Gosset (筆名 "Student") 1908 이후 R.A. Fisher (1926)에 의해 完全히 究明되 이와 같은 確率變數 t 의 分布를 自由度 $n-1$ 의 "Student t-分布"라고 한다. 따라서 10名의 學生에 대한 母集團平均 μ_1 이 $\mu = 162 cm$ 와 같다고 하는 前提아래 計測하면

$$S^2 = 1 / (10 - 1) \times 10 \times 25 = 27.78$$

$$t = \frac{164 - 162}{\sqrt{27.28} / \sqrt{25}} = 1.897$$

을 얻게 되며 自由度 $10 - 1 = 9$ 인 t 分布는 數值表에서 $t_0 = 3.25$ 보다 큰 確率은 0.01 이므로 $t = 1.897$ 보다 큰 確率은 0.01 보다 큰 것이라는 것을 알 수 있다. 따라서 이 假說은 棄却할 必要가 없으며 母平均이 162cm 의 母集團에서 抽出한 標本이 10 個인 경우에는 標本平均이 164cm 의 數值를 나타낼 수 있다는 것을 보여 준다. 一般的으로 크기가 n 인 標本平均 $\bar{x}$ 가 母平均 μ 의 集團에 속하는가 그렇지 않는가를 決定하는데 있어서는 「標本平均 $\bar{x}$ 의 母平均은 μ 이다」라는 假定아래

- ① $|t| > t_0$ 이면 H_0 를 棄却하고
- ② $|t| < t_0$ 이면 H_0 를 採択한다.

(2) 比率의 檢定

比率의 檢定은 간단한 例로서 설명해 보기로 한다.

即, 어떤 生産工場에서 A製品을 使用하는 需要者가 80% 되리라고 생각하여 標本으로 100 世帶를 抽出하여 調査한 結果 A製品을 使用하는 世帶가 72 世帶였다면 歸無假說은 採択되어질 수 있을까 하는 問題가 된다.

우리는 假說로써 $H_0 : P = 0.8$ 을 設定하게 되며 이 때의 有意

水準을 5%라고 하면 標本 $x_1, x_2, \dots, x_n$ 에 대한 統計量 Z 의 函数은

$$Z = \frac{\bar{x} - np}{\sqrt{np(1-p)}}$$

가 되며 이를 計算하면

$$Z = \frac{72 - 100(0.8)}{\sqrt{100(0.8)(0.2)}} = -2.00$$

을 얻는다. 그런데 正規分布의 3σ 범위는 片側檢定の $0.5 - 0.05 = 0.45$ 로서 ± 1.64 를 얻게 되므로 다음과 같은 判定을 提示할 수 있다.

即 「72世帯가 A製品을 使用하는 것으로 나타난 Z 分布는 -2.00 이며 標本에서 얻은 값은 ± 1.64 이므로 帰無假說을 기각되지 않을 수 없으며 生産業者 危險을 招來하고 있다」라고 생각할 수 있으므로 이 生産工場으로서의 統計的 決定은 잘못된 것임을 알 수 있다.

(3) 平均值差에 대한 檢定

(A) 大標本일 경우

어느 두 地方 A, B에 있어서의 企業體들 사이에 未熟練工에게 支拂하는 月平均賃金에 差異가 있는가 하는 것을 알아보기 위하여 이 두 地方에서 각각 100名, 200名을 標本으로 취하여 그들에게 支給되는 賃金を 調査하여 다음과 같은 結果를 얻었다.

지금 A, B 두 地方에서 月平均賃金에 관한 母平均을 각각 μ_1 ,

地方	平 均	標 準 偏 差	標本の 크기
A	$\bar{x}_1 = \text{₩ } 18,002$	$S_1 = \text{₩ } 800$	$n_1 = 100$
B	$\bar{x}_2 = \text{₩ } 17,042$	$S_2 = \text{₩ } 900$	$n_2 = 200$

μ_2 라고 母標準偏差를 각각 σ_1, σ_2 라고 하자. 그러면 이 問題에서 檢定하려는 假說은 다음과 같이 된다.

帰無假說 $H_0 : \mu_1 = \mu_2$

対立假說 $H_1 : \mu_1 \neq \mu_2$

数理統計学에 의하면 平均과 標準偏差가 각각 μ_1, σ_1 그리고 μ_2, σ_2 인 두 正規母集團에서 각각 크기 n_1, n_2 의 서로 獨立인 任意標本을 취하였을 경우의 標本平均을 각각 $\bar{x}_1, \bar{x}_2$ 로 表示한다면 標本平均値差 $\bar{x}_1 - \bar{x}_2$ 의 分布는 다음과 같이 된다. 즉

$\bar{x}_1 - \bar{x}_2$ 는 平均이 $\mu_1 - \mu_2$, 標準偏差가 $\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$ 인 正規分布를 한다. 이것은

$$Z = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

로 놓으면 Z 는 平均이 0, 標準偏差가 1인 소위 標準正規分布를 한다.

그런데 대개의 경우 두 母集團의 標準偏差 σ_1, σ_2 를 알지 못하는 것이 보통일 것이다. 그러나 이러한 경우에도 標本の 크기가

클 때에는 ($n_1 > 30, n_2 > 30$), σ_1, σ_2 대신 標本標準偏差 S_1, S_2 를 그대로 使用하여도 무방하다. 따라서, 위의 例의 假說 檢定은 H_0 하에서 $\mu_1 - \mu_2 = 0$ 이므로

$$Z = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} = \frac{18,002 - 17,042}{\sqrt{\frac{(800)^2}{100} + \frac{(900)^2}{200}}} = 9.4$$

여기에서 有意水準을 1%로 한다면 數值表에서 $P(|Z| \geq Z_{.01}) = 0.01$ 로 되는 $Z_{.01}$ 값으로 2.58을 얻는다. 즉 A, B 두 地方에서의 未熟練工에 대한 賃金差가 있다는 結論을 얻게 된다.

(B) 小標本일 경우

平均이 각각 μ_1, μ_2 이고 標準偏差가 각각 σ_1, σ_2 인 두 개의 正規母集團에서 標本の 크기가 각각 n_1, n_2 ($n_1 < 30, n_2 < 30$)인 獨立標本에서의 標本平均値를 $\bar{x}_1, \bar{x}_2$ 그리고 σ_1^2, σ_2^2 에 대한 不偏推定値를 각각 S_1^2, S_2^2 라고 하자. 이때 n_1, n_2 가 크지 않으므로

$$t = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}}$$

가 標準正規分布에 近似的으로 따른다고 할 수는 없는 것이다.

그러면 t -分布를 하는 것일까? 여기에서 만약 $\sigma_1 = \sigma_2 = \sigma$ 와 같은 假定이 成立한다면 大標本에서 Z 는 즉

$$Z = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\sigma^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}}$$

와 같이 된다. 이와 같은 경우 共同分散 σ^2 에 대한 不偏推定值 S^2 은 다음과 같이 구한다.

$$S^2 = \frac{(n_1 - 1) S_1^2 + (n_2 - 1) S_2^2}{n_1 + n_2 - 2}$$

그래서 σ^2 에 S^2 을 代入한 式

$$t = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{S^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}}$$

는 自由度 $n_1 + n_2 - 2$ 인 t -分布를 하게 된다.

例. B.1 交信方法과 問題를 解決하는 能力에 관한 研究結果를 보자. 實驗者는 任意로 세 集團을 抽出하고 각 集團에 똑같은 問題를 解決하도록 한다. 그러나 각 集團内에서의 交信方法은 集團別로 다르게 하였다. 즉 첫째 集團은 모든 方法을 다 쓰도록 (all channel pattern) 하였고, 두번째 集團에서는 “차바퀴” 패턴 (wheel pattern) 을, 세째 集團에서는 “원” 패턴 (circle pattern) 에 의하여 交信토록 하였다. 다음表는 제 2, 제 3 集團에 대한 實驗結果이다.

問題解決에 所要되는 時間 (單位: 分)

交信패턴	平 均	標 準 偏 差	標本의 크기
차바퀴	$\bar{x}_2 = 19.12$	$S_2 = 3.20$	15
원	$\bar{x}_3 = 29.45$	$S_3 = 5.21$	21

이때 檢定하려는 假說은 다음과 같을 것이다.

帰無假說 $H_0 : \mu_2 = \mu_3$

対立假說 $H_1 : \mu_2 \neq \mu_3$

그리고 이와 같은 假說에 대한 檢定은 위의 t 값을 計算하는 것으로 이루어진다. 그런데 이에 앞서서 두 母分散 σ_2^2, σ_3^2 의 同一性を 確認할 必要가 있다. 그러나 여기에서는 $\sigma_2^2 = \sigma_3^2 = \sigma^2$ 이라고 假定하고 檢定節次를 進行하기로 한다.

우선 σ^2 에 대한 推定值 S^2 을 구한다.

$$S^2 = \frac{(14)(3.20)^2 + (20)(5.21)^2}{15 + 21 - 2} = 20.1836$$

그러므로 帰無假說下에서 t 값은 다음과 같이 計算된다.

$$t = \frac{|19.12 - 29.45|}{\sqrt{20.1836 \left(\frac{1}{15} + \frac{1}{21} \right)}} = 6.8$$

한편 有意水準 5%下에서 自由度 34 일 때의 $t_{.05}$ 의 값은 2.042 정도 이므로 결국 帰無假說 $\mu_2 = \mu_3$ 는 棄却된다.

(C) $\sigma_1 \neq \sigma_2$ 일 때의 檢定法

두 獨立任意標本の 平均值差를 이용하여 母平均值差에 대한 檢定을 한다든가 또는 信賴區間의 구하는 데 있어서 두 母集團標準偏差가 서로 같다고 하는 假定이 의심스러운 때가 많다. 예를 들면 (1) 性質이 다른 두 母集團에 있어서는 이들 各母標準偏差가

서로 같다고 보기 어려운 때가 많다. 한 가지 例로 私立国民学校 学生과 公立国民学校 学生 사이의 어떤 特性을 比較하려고 할 때, 私立学校 学生들 間의 標準偏差와 公立学校 学生들 間의 標準偏差가 같으리라고는 믿기는 어려운 것이다. (2) 두 母集團의 각각의 母平均에 대한 信賴區間을 구하였을 때 區間的 幅이 서로 크게 다른 경우 母平均値間의 差異에 따라서 母標準偏差에도 差異를 나타내는 일이 많다. 따라서 이와 같은 경우 $\sigma_1 = \sigma_2$ 라고 假定하기는 어렵다. (3) 母集團의 分布狀態가 對稱型에서 크게 벗어나 있을 때는 平均 μ 와 標準偏差 σ 사이에 關係성이 濃厚한 때가 많다. 즉 $\mu_1 = \mu_2$ 이면 $\sigma_1 > \sigma_2$ 와 같은 關係가 있기 쉬운 것이다.

그런데 $\sigma_1 \neq \sigma_2$ 라고 생각될 경우에도 두 獨立任意標本에 있어서 標本平均値差 $\bar{x}_1 - \bar{x}_2$ 의 分散은 역시 $\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}$ 와 같이 된다. 그러나 이와 같은 경우 $\mu_1 = \mu_2$ 인 歸無假說下에서

$$t' = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}}$$

는 理論上 "Student"의 t -分布를 하지 않는 것으로 되어 있다.

이와 같은 경우 $H_0 : \mu_1 = \mu_2$ 를 檢定하는 問題에 대하여 Behrens와 Fisher의 解法이 있고 그 外의 여러가지 方法이 있으나 여기에서는 Cochran의 方法을 소개하기로 한다.

$$n_1 = n_2 = n \text{의 경우 이때에는 } s^2 = \frac{s_1^2 + s_2^2}{2}$$

으로 놓으면 위의 식은

$$t' = \frac{\sqrt{n} (x_1 - x_2)}{s \sqrt{2}} \text{ 이다.}$$

이것은 $\sigma_1 = \sigma_2 = \sigma$ 일 때의 식과 다를 것이 없는 것이지만
그러나 이 t' 의 값은 자유도 $n-1$ ($2n-2$ 가 아님)인 t -
분포에 近似하게 分布한다는 것을 利用하여야 한다.

$n_1 \neq n_2$ 일 경우 例 B1 에서 $\sigma_1 \neq \sigma_2$ 라고 假定하면 우선

$$t' = \frac{|19.12 - 29.45|}{\sqrt{\frac{(3.20)^2}{15} + \frac{(5.21)^2}{21}}} = 7.35$$

를 구한다. 이때 t' 에 대한 有意水準 값은 다음과 같이 計算
한다.

$$\frac{w_1 t_1 + w_2 t_2}{w_1 + w_2}$$

여기에서 $w_1 = s_1^2/n_1$, $w_2 = s_2^2/n_2$ 이고, t_1, t_2 는 자유도
 $n_1 - 1, n_2 - 1$ 에 対応하는 t 分布表에서의 값 (有意水準 5%)
이다.

이 例에서는

$$t_1 = 2.145, \quad t_2 = 2.086$$

$$\text{그리고 } w_1 = 0.6827, \quad w_2 = 1.2926$$

그러면

$$t'_{.05} = \frac{(0.6827)(2.145) + (1.2926)(2.086)}{0.6827 + 1.2926} = 2.1064$$

와 같이 되고 결국

$$t' > t'_{.05}$$

와 같이 되므로 이때에도 帰無假說은 棄却된다.

(4) 比率의 差에 대한 檢定

母比率이 P_1, P_2 인 두 母集團이 있다. 이들 두 母集團에서 크기가 각각 n_1, n_2 ($n_1 > 30, n_2 > 30$) 인 任意標本을 抽出하여 標本比率 P_1, P_2 를 얻었다고 하자. 그러면 n_1, n_2 가 커지면 이에 따라 P_1, P_2 의 分布는 각각 平均이 P_1, P_2 , 分散이 $P_1 Q_1 / n_1, P_2 Q_2 / n_2$ 인 正規分布에 接近하여 간다. 여기에서 $Q_1 = 1 - P_1, Q_2 = 1 - P_2$ 이다. 그러므로 標本比率差 $P_1 - P_2$ 는 平均이 $P_1 - P_2$, 標準偏差가 $\sqrt{\frac{P_1 Q_1}{n_1} + \frac{P_2 Q_2}{n_2}}$ 인 正規分布에 가까워 진다.

여기에서 다음과 같은 假說檢定을 생각한다.

帰無假說 $H_0 : P_1 = P_2$

이와같은 경우

$$Z = \frac{P_1 - P_2}{\sqrt{\frac{P_1 Q_1}{n_1} + \frac{P_2 Q_2}{n_2}}}$$

가 近似的으로 標準正規分布를 한다는 것을 利用할 수 있을 것이

라고 생각된다. 그러나 母比率 P_1, P_2 는 알지 못한다. 그러므로 H_0 下에서 $P_1 = P_2 = P$ 의 推定値 P 를 구하려고 할 것이다. 이때 推定比 P 는 다음과 같이 구해진다.

$$P = \frac{n_1 P_1 + n_2 P_2}{n_1 + n_2}$$

그리고 n_1, n_2 가 다같이 클 때에는

$$Z = \frac{P_1 - P_2}{\sqrt{pq \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}}, \quad q = 1 - P$$

가 標準正規分布에 接近하여 간다는 事實에 의하여 H_0 를 檢定하게 되는 것이다.

例 (4). 1 美国南部에서의 한 選舉에서 白人投票者 중에서 任意로 抽出된 655 名중 203 名이 民主党 후보에게 投票을 했고 黑人投票者중에서 任意로 抽出된 480 名중 173 名이 민주당 후보에게 投票을 하였다는 것을 알고 있다. 黑人の 民主党 支持度가 白人の 그것보다 높다고 할 수 있을 것인가?

민주당원에 投票한 標本比率은 각각 다음과 같다.

$$P_1 = \frac{203}{655} = 0.31, \quad P_2 = \frac{173}{480} = 0.36$$

그리고 이때 檢定을 위한 假說은 다음과 같다.

$$H_0 : P_1 = P_2, \quad H_1 : P_1 \neq P_2$$

이 例에서 帰無假說 $P_1 = P_2 = P$ 下에서 P 의 推定値는

$$P = \frac{203 + 173}{655 + 480} = 0.33$$

와 같이 되므로

$$Z = \frac{|0.31 - 0.36|}{\sqrt{(0.33)(0.67) \left(\frac{1}{655} + \frac{1}{480}\right)}} = 1.8$$

한편 正規分布表에서 有意水準 5%에서 $Z_{.05} = 1.96$ 을 얻으므로 결국 $Z < Z_{.05}$ 와 같이 되어 帰無假說 $P_1 = P_2$ 는 棄却되지 않는다.

(5) 分散의 同一性에 관한 檢定

$\sigma_1 = \sigma_2$ 와 같이 假定하기가 어려울 때는 帰無假說 $H_0 :$
 $\sigma_1 = \sigma_2$, 對立假說 $H_1 : \sigma_1 \neq \sigma_2$ 를 세우고 이것을 獨立任意標本에서 計算한 標本分散 S_1^2 과 S_2^2 에 의한 分散比 $F = S_1^2 / S_2^2$
 (단 $S_1^2 > S_2^2$ 일때) 를 利用하여 假說檢定을 한다. 統計量 F 의
 確率分布는 $Z = 1/2 \log_e F$ 와 같이 變換한 다음에 Z 의 分布로서
 1924年 R.A. Fisher 에 의하여 유도되었다. 이와 같은 Z -分
 布 대신에 F 의 直接的인 確率分布를 사용한 사람은 G.W.
 Snedecor (Statistical Methods, 1940) 이다. 이와 같은 事實
 에서 "Snedecor 의 F -分布" 라는 名称이 붙게 되었다. F -分
 布는 χ^2 -分布나 t -分布와 같이 統計學理論과 實際面에서 重要な
 役割을 하는 分布이다.

例 B.1에서 $H_1 : \sigma_1 \neq \sigma_2$ 에 대한 $H_0 : \sigma_1 = \sigma_2$ 를 檢定해
 보기로 한다.

$$S_1^2 = (3.20)^2 = 10.2400$$

$$S_2^2 = (5.21)^2 = 27.1441$$

을 얻는다. 따라서

$$F = S_2^2 / S_1^2 = 2.65$$

와 같은 分散比를 얻고 自由度는 分子 $f_1 = 21 - 1 = 20$, 分母 $f_2 = 15 - 1 = 14$ 이다. 한편 數值表에서 $f_1 = 20$, $f_2 = 14$ 에 대한 $F_{.05}$ 값은 보간법에 의하여 2.86 으로 된다는 것을 알 수가 있다.

즉 $F < F_{.05}$, 따라서 이 例에서는 假說 H_0 가 기각되지 않는다. 그런데 이 例에서는 檢定이 兩側檢定이지만 많은 경우 對立假說로서 $\sigma_1 < \sigma_2$ 와 같이 設定되는 것이 많기 때문에 單側檢定을 하는 때가 많다.

3.3 非母數的 檢定

(1) χ^2 -檢定

非母數法에 의한 有意性 檢定中 應用範圍가 가장 넓은 것이 χ^2 -檢定이다. 이 χ^2 -檢定은 1900年 K.Pearson에 의해서 처음 考察된 것으로 χ^2 -分布를 應用하여 몇 가지 屬性間에 獨立性이 認定되는 가를 檢定하고, 實驗統計가 理論的인 既知分布에 어느 정도 適合되는가를 檢定하는데 使用되고 있다. 以下에서는 먼저 χ^2 이 가지는 意味를 說明하고, 適合度의 檢定과 獨立性의 檢定(分割表의 檢定)에 대하여 詳述한다.

(A) χ^2 의 意味

어떤 標本에 있어서 事象 $E_1, E_2, \dots, E_k$ 의 實際 觀察度數를 $f_1, f_2, \dots, f_k$ 라 하고 期待度數 또는 理論度數를 $F_1, F_2, \dots, F_k$ 라 하였을 때, 經驗値와 理論値와의 差의 自乘을 理論値로 나눈 값의 合計, 即 χ^2 은 다음과 같이 定義할 수 있다.

$$\chi^2 = \sum_{i=1}^k \frac{(f_i - F_i)^2}{F_i}$$

여기에서 觀察度數 f_i 는 離散變數이므로 위의 식에 의한 χ^2 도 離散變數이다. 그리고 위 式에서 $\chi^2 = 0$ 이면 理論度數와 觀察度數는 一致하나 $\chi^2 > 0$ 이면 兩者는 一致하지 않고 χ^2 의 값이 클수록 兩者의 差가 큼을 意味한다.

(B) 適合度의 檢定

適合度의 檢定 또는 度數分布表의 適合度 檢定이란 經驗的인 度數分布가 理論的인 分布에 適合하는가 않는가를 觀察하는 것으로, 이러한 度數分布의 適合度의 檢定은 二項分布, 포아송分布, 正規分布, 其他 任意의 理論的 分布에 대해서도 마찬가지로 檢定을 할 수 있고 또 離散分布나 連續分布의 경우에도 할 수 있다.

이 경우 理論的 分布가 주어져 있는 경우(單純假說)와 이것이 주어지지 않아서 標本觀察의 結果에서 이것을 推定하여 하는 경우(複合假說)의 두가지가 있으나 後者가 一般的이다. 여기에서는

檢定方法과 二項分布 및 正規分布의 適合度의 檢定에 대해서 간단히 說明하고자 한다.

① 檢定方法

檢定假說을 먼저 세운후 이 假說에 의한 理論度數 F 를 求하여 觀察度數 f 와 理論度數 F 와의 差의 平方을 F 로 除하여 檢定統計量 χ^2 을 구한다. 다음 自由度 ν 를 구한다. 自由度 ν 는 階級個數 k , 理論度數를 定하는 既知의 母數를 ℓ 이라면 $\nu = (k - 1) - \ell$ 이다. 그러나 理論度數 가운데 5 以下の 度數가 포함되어 있을 때에는 度數를 適當히 併合하여 모두 5 以上 되게 해야 한다. k 가 5 보다 작으면 理論度數는 相當히 커야 한다. 여기에서 有意水準을 α 라 하면 自由度 $(k - 1) - \ell$ 의 χ^2 數值表에서 χ^2_α 를 구한 다음

$\chi^2 > \chi^2_\alpha$ 이면 假說을 棄却

$\chi^2 \leq \chi^2_\alpha$ 이면 假說을 採択한다는 方法이다.

② 二項分布에 관한 適合度의 檢定

觀察度數의 總合을 N 이라고 할때 確率變數 $x = 0, 1, 2, \dots$ 의 確率을 ${}_nC_x p^x q^{n-x}$ 에 의하여 求하고 여기에 N 을 乘하면 確率變數 $x = 0, 1, 2, \dots$ 의 理論度數가 된다. 즉 理論度數 $F_x = N {}_nC_x p^x q^{n-x}$ 로 計算된다. 그리고 期待度數(理論度數)中에 5 以下가 있으면 이웃간의 期待度數와 合쳐서 5 以上이 되도록 한다.

自由度는 二項分布의 경우 母數는 n, p 의 2개이나 p 의 값은

未知의 경우가 많고 既知母數는 上述한 바와 같이 n 하나라면 $l=1$ 이므로 $v=k-1-1=k-2$ 이다. 그리고 다음 節次는 檢定方法에서 詳述한 것과 같이 한다.

(3) 正規分布에 관한 適合度の 檢定

正規分布에서는 標準正規變數

$$Z = \frac{x - \bar{x}}{\sigma \text{ (或은 } S)}$$

를 가지고 數值表에서 各級을 確率을 구한 다음 여기에 n 을 곱하면 理論度數 F 를 구할 수 있으므로 이 理論度數와 觀察度數 f 를 가지고 위의 檢定方法에 따라 計算한다. 그리고 이 경우 既知的 母數는 μ, σ 의 2개이므로 自由度는 $v=k-1-2=k-3$ 이 된다.

(C) 獨立性的 χ^2 檢定

크기 n 인 標本에 대하여 要因 x, y 에 대하여 아래와 같은 分割表가 주어져 있을 경우 分割表에 나타난 關係가 有意인가 아닌가를 檢定하려 할때에 이 2分類標準이 서로 無關係라고 假定하고 이것을 檢定假說로 하여 χ^2 -檢定을 하는 것을 말한다. 이때의 分割表는 2개의 質的分類를 組合한 2重分類表이다.

$y \backslash x$	x_1	x_2		x_j		x_l	計
y_1	f_{11}	f_{12}		f_{1j}		f_{1l}	$f_{1.}$
y_2	f_{21}	f_{22}		f_{2j}		f_{2l}	$f_{2.}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
y_i	f_{i1}	f_{i2}		f_{ij}		f_{il}	$f_{i.}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
y_k	f_{k1}	f_{k2}		f_{kj}		f_{kl}	$f_{k.}$
計	$f_{.1}$	$f_{.2}$		$f_{.j}$		$f_{.l}$	n

檢定方法은 위 表에서 觀察度數 f_{ij} 에 대한 理論度數 F_{ij} 를 다음과 같이 $F_{ij} = f_{i.} \cdot f_{.j} / n$ 을 구한 다음 x 와 y 가 無關係라는 것을 檢定假說로 하여 檢定統計量을 다음 式으로 計算한다.

$$\chi^2 = \sum_i \sum_j \frac{(f_{ij} - F_{ij})^2}{F_{ij}}$$

여기서는 k 行 l 列 分割表의 경우이므로 自由度 ν 는 $(k-1)(l-1)$ 이며 以下는 適合度檢定에서의 節次와 같다.

例. 95명을 머리카락의 빛깔과 눈의 빛깔에 따라 分類하여, 다음表를 얻었다. 머리카락의 빛깔과, 눈의 빛깔은 無關係일까?

解. $m=3$, $n=2$ 이고, $N=95$ 인 경우이다. 여기에서 假說은 「頭髮色과 眼色은 서로 無關係이다」이고 理論度數의 計算은

眼色 \ 頭髮色	金 髮	黑 髮	計
青 色	32 (24.1)	12 (19.9)	44
茶 色	14 (19.7)	22 (16.3)	36
灰 色	6 (8.2)	9 (6.8)	15
計	52	43	95

$$\text{青眼金髮} = 52/95 \times 44 = 24.1$$

茶眼金髮 $52/95 \times 36 = 19.7$ 이며 나머지는 다음과 같이 정해진다.

$$\text{灰眼金髮} = 8.2$$

$$\text{青眼黑髮} = 19.9$$

$$\text{茶眼黑髮} = 16.3$$

$$\text{灰眼黑髮} = 6.8$$

이 理論度數를 해당하는 欄의 () 안에 적어 넣었다. 위의 6 個의 理論度數 중에서 自由로 정할 수 있는 것은 2 個 뿐이다. 즉 自由度는 $2 \times 1 = 2$ 이다.

이 觀察에서의 χ^2 값은

$$\chi^2 = \sum_{i=1}^3 \sum_{j=1}^2 \frac{(f_{ij} - F_{ij})^2}{F_{ij}} = 10.67$$

自由度 2 일 때의 χ^2 -分布의 5%점은 $\chi^2_{.05} = 5.99$ 이므로 假說은 5% 有意水準에서 棄却된다. 即 두 빛깔 사이에는 서로 關聯性이 있다는 말이다.

① 2×2 分割表의 簡便式

이때에는 다음과 같이 計算이 簡便化 된다.

$y \backslash x$	x_1	x_2	計
y_1	f_1	f_2	$f_1 + f_2$
y_2	f_3	f_4	$f_3 + f_4$
計	$f_1 + f_3$	$f_2 + f_4$	$\sum f = n$

即

$$\chi^2 = \frac{n (f_1 f_4 - f_2 f_3)^2}{(f_1 + f_3) (f_2 + f_4) (f_1 + f_2) (f_3 + f_4)}$$

이때 自由度는 $\nu = 1$ 이다. 그리고 檢定方法은 앞에서와 같다.

2×3 分割表의 경우에도 簡易하게 하는 方法이 있다.

② Yates의 修正係數

그런데 2×2 分割表와 같이 階級別 度수가운데에 5 보다 작은 것이 있을 때는 元來 Stirling의 公式을 使用함으로써 誘導된 χ^2 分布表를 그대로 利用함에는 너무나 誤差가 클것이므로 所謂 Yates의 修正을 하는 例가 많다.

이는 곧 真正한 數值(修正值) x 의 數量을 現實的인 度數 n 에 대하여 $(n - 0.5) < x < (n + 0.5)$ 로 생각하고 處理하는 方法이 된다. 즉 修正值 χ^2 은

$$\chi^2 (\text{수정치}) = \sum_{i=1}^k \frac{(|f_i - F_i| - 0.5)^2}{F_i}$$

그러나 Yates의 修正은 2×2 分割表 以外에는 一般的으로 實施되지 않는다.

(3) 比率差의 檢定

여기서는 比率의 差에 관한 檢定을 χ^2 -分布를 利用하여서도 할 수 있다는 것을 보여주기로 한다. 우선 例 B . 1 을 다음과 같이 2×2 分割表로 정리한다.

	白 人	黒 人	計
민주당 후보에게 투표한 사람수	203	173	376
민주당 후보가 아닌 자에게 투표한 사람수	452	307	759
計	655	480	1,135

이때 다음과 같은 χ^2 값을 計算하여 檢定할 수 있는 것이다.

$$\chi^2 = \sum (f - F)^2 / F$$

단, f 는 觀測度数 203, 452, 173, 307 을 表示하고 F 는 帰無假說下에서 期待되는 理論度数를 나타낸다.

白人이나 黒人이나 민주당 후보에 投票하는 比率은 같다는 假定下에서의 投票率 P 는 위에서 說明한 바와 마찬가지로 表의 合計란을 利用하여 $376/1135$ 으로 된다. 따라서 白人 655 名中에서 이러한 比率로 민주당 후보에 投票하는 人員數는 $655 \times 376/1135 = 216.99$ 와 같이 計算된다. 이것이 觀測度数 203 에 대

하여 기대되는 理論度数 (期待度数) 인 것이다.

어떤 觀測度数에 대한 期待度수를 구하는 方法은 그가 속해 있는 行과 列의 合計를 서로 곱한 다음에 總計로 나누어서 구해진다. 黑人 480 名중 민주당 후보에 投票하는 期待度수는 이것이 속해 있는 行의 合計 376 과 列의 合計 480 을 서로 곱한 다음에 總計 1,135 로 나누어서 구해진다. 即 $376 \times 480 / 1135 = 159.01$ 과 같이 計算된다.

아래 表는 f 값과 이에 代應하는 F 그리고 $f - F$ 값을 表示한다.

f , F 및 $f - F$ 表

203	173	261.99	159.01	-13.99	13.99
452	307	438.01	320.99	13.99	-13.99
f		F		$f - F$	

그런데 $(f - F)^2$ 은 어느 것이나 다같이 $(13.99)^2$ 이라는 것을 알 수가 있다. 2×2 分割表에서는 언제나 이와 같이 된다는 것이 特徵이다. 그러므로 2×2 分割表에서의 χ^2 -값 計算公式를 다음과 같이 고쳐서 使用하는 것이 편리하다.

$$\begin{aligned}
 \chi^2 &= (f - F)^2 \sum \frac{1}{F} \\
 &= (13.99)^2 \left(\frac{1}{216.99} + \frac{1}{438.01} + \frac{1}{159.01} + \frac{1}{320.99} \right) \\
 &= 3.2098
 \end{aligned}$$

그러면 이때 自由度는 위表에서 알 수 있는 바와 같이 偏差 $f - F$ 는 符号를 除外하고는 똑같은 값을 갖는다.

그러므로 Fisher에 의하여 証明된 바와 같이 自由度는 단지 1이다. 따라서 自由度 1인 χ^2 -分布表에서 有意水準 5%인 값 3.84와 비교해 보면 $\chi^2 < \chi_{.05}^2$ 이므로 假說은 기각되지 않는다. 그런데 이와 같은 경우 χ^2 -값의 連續性에 대한 補正이 必要하게 된다. 補正된 χ^2 값은 다음과 같이 된다.

$$\begin{aligned}\chi_c^2 &= (|f - F| - 0.5)^2 \sum \frac{1}{F} \\ &= 2.98\end{aligned}$$

(2) 符号檢定 (The sign test)

어느 特徵을 數量的으로 表示할 수 없을 때가 간혹 있으나 좋다, 나쁘다, 또는 제일 맛이 있다. 두번째로 맛이 있다, 세번째로 맛이 있다, 맛이 없다 등과 같이 等級을 매길 수 있는 경우는 많이 있다. 다음 表는 두 種類의 食品에 대하여 8名의 감정자가 각각 두 음식을 試食한 다음에 맛이 있는 順序에 따라서 1, 2로 順位를 정한 것이다.

여기에서 두 種類의 食品이라는 것은 쇠고기를 가정용 冷蔵庫에 0°F로 저장하였다가 만든 작은 쇠고기 파이어이고, 또 하나는 0° ~ 15°F의 變溫中에 저장하였다가 만든 파이어이다. 맛이라고 한 것은 주로 맛 향기에 대하여 感정한 것이다.

쇠고기 파이에 대한 香氣의 順位

감 정 자	0 °F	變溫 (0° ~ 15 °F)
A	1	2
B	1	2
C	2	1
D	1	2
E	1	2
F	1	2
G	1	2
H	1	2

이때 檢定을 위한 帰無假說로는 두 가지를 생각할 수 있다.
 하나는 0° ~ 15 °F의 變溫中에 쇠고기를 저장하였다가 만든 파이가
 0 °F의 定溫中에 저장하였다가 만든 파이와 조금도 다를 것이 없
 다는 것이고, 또 하나의 생각할 수 있는 帰無假說은 파이의 향기
 에는 差異가 있는 것이 確實하지만 감정자의 半인 4名은 0 °F의
 定溫에 저장하였다가 만든 파이의 향기를 좋아하고, 나머지 半인
 4名은 0° ~ 15 °F의 變溫中에 저장하였다가 만든 파이의 향기를
 좋아 한다는 假說이다. 그러나 이들 두가지중 어떤 것을 帰無假
 說로 設定하든간에 0 °F의 定溫中에 저장하였다가 만든 파이가 1
 번으로 될 確率は 1/2이다. 따라서 이와 같은 假說下에서는 8
 名중 4名이 0 °F에서 저장하였다가 만든 파이에 1번을 매기게

될 것을 기대할 수가 있다. 그러나 실제에 있어서는 이것이 7
명과 1명으로 觀測된 것이다. 이와 같은 假說을 檢定하는데 있
어서 가장 적절한 方法은 χ^2 -檢定法이라는 것을 理解하기 어렵지
않을 것이다. 위의 例에서 χ^2 값은 다음과 같이 計算된다.

$$\chi^2 = (7-4)^2 / 4 + (1-4)^2 / 4 = 4.5$$

이와같은 歸無假說을 檢定하는 경우에는 다음과 같은 便利한 公
式을 利用할 수가 있다.

$$\chi^2 = (a-b)^2 / n = (7-1)^2 / 8 = 4.5$$

단, a, b 는 두 가지 種類에 대한 個數이고 $n = a + b$ 이다.

그런데 標本의 크기 n 이 작을 때는 위의 公式을 修正한 다음과
같은 公式을 使用하여야 한다.

$$\begin{aligned} \chi^2 &= (|a-b|-1)^2 / n = (|7-1|-1)^2 / 8 \\ &= (6-1)^2 / 8 = 3.12 \quad P=0.078 \end{aligned}$$

따라서 위의 例의 경우 5% 有意水準下에서 假說은 棄却되지
않는다.

이와 같은 χ^2 -檢定은 正規分布를 假定하였을 때의 対応이 있는
짝지은 實驗에 의하여 母平均値差를 比較하는 檢定과 對等한 것이
라고 할 수 있다. 그리고 위의 例에서 1, 2와 같은 順位番号
대신에 +, -등의 符號를 使用하는 경우가 많으므로 위에서의 檢
定을 符號檢定(the sign test)이라고 한다.

符號檢定の 경우 아래表를 利用하면 χ^2 값을 計算할 必要없이 直
接 檢定할 수가 있다.

符号檢定에 있어서 各有意水準에 대한 같은 符号數 (判호안의 數字는 실제 確率) < 兩側 檢定用 >

표본의 크기	有 意 水 準		
	1 %	5 %	10 %
5			0 (.062)
6		0 (.031)	0 (.031)
7		0 (.061)	0 (.016)
8	0 (.008)	0 (.008)	1 (.070)
9	0 (.004)	1 (.039)	1 (.039)
10	0 (.002)	1 (.021)	1 (.021)
11	0 (.001)	1 (.012)	2 (.065)
12	1 (.006)	2 (.039)	2 (.039)
13	1 (.003)	2 (.022)	3 (.092)
14	1 (.002)	2 (.013)	3 (.057)
15	2 (.007)	3 (.035)	3 (.035)
16	2 (.004)	3 (.021)	4 (.077)
17	2 (.002)	4 (.049)	4 (.049)
18	3 (.008)	4 (.031)	5 (.096)
19	3 (.004)	4 (.019)	5 (.063)
20	3 (.003)	5 (.041)	5 (.041)

※ 判호안의 숫자는 正確한 有意水準값을 나타낸다.

(3) 測定値間の 差에 順位를 매겨 檢定하는 方法(The signed rank test)

対応이 있는 짝지은 標本抽出에 의한 두 母平均値差를 檢定하는 t -檢定과 對等한 檢定方法을 符号檢定法이라고 하였으나, 또 한가지 方法으로 Wilcoxon의 符号가 붙은 順位檢定法(the signed rank test)이라는 것이 있다. 이 두 가지 方法은 한 資料에 대하여 다같이 適用할 수 있는 것이지만 여기에서 說明하는 方法이 資料에 따라서는 檢定力(檢定の 感度)이 높은 것으로 되어 있다.

이 方法은 처음에 짝지어진 각각의 測定値差를 구한다. 그러면 이 差에는 + 또는 -符号가 따를 것이지만 이 符号를 無視하고 差의 絶對値가 작은 것부터 順番으로 1, 2, 3,과 같이 番号를 붙인다. 그 다음에 이 番号에 測定値差에 붙어 있는 符号+ 또는 -를 붙인다. 그리고 符号別 番号合計値를 구하고 이 값을 利用하여 檢定을 하게 된다.

例. 한 兒童心理學者가 어린이가 保育園에 다니는 것이 그들의 社会的 知覺力에 영향을 끼치는가를 알아보기 위하여 다음과 같은 實驗을 하였다. 8쌍의 쌍둥이를 利用하여 각쌍의 쌍둥이 중에서 한 아이를 保育園에 다니게 하고 한 아이는 집에서 놀게 하였다. 그리고 얼마후에 어떤 檢査를 거쳐서 다음과 같은 社会的 知覺力에 관한 点数表를 얻었다.

社会的 知覺力에 대한 檢査点数

쌍둥이 번 호	保育院에 다닌 아이들의 社会 的 知覺力	집에서 놀던 아이들의 社会 的 知覺力	差 d	d의 順位	-번호	+번호
1	82	63	19	7		7
2	69	42	27	8		8
3	73	74	-1	-1	1	
4	43	37	6	4		4
5	58	51	7	5		5
6	56	43	13	6		6
7	76	80	-4	-3	3	
8	65	62	3	2		2
				計	4	32

이 表에서 差 d 에 대하여 +, - 符号에 關係없이 우선 差의 크기의 絶對值에 의하여 順位番号를 붙이고 그 다음에 差의 符号를 順位番号에 붙인 것이다. 이 例에서 다음과 같은 帰無假說을 設定한다.

帰無假說 H_0 : 社会的 知覺力에 있어서 保育院에 다닌 아이와 집에서 놀던 아이 사이에는 差異가 없다.

이것을 Wilcoxon 檢定에서 使用하는 用語로 表現하면 다음과 같이 된다.

H_0 : 負數 d 에 対応하는 順位番号의 合計 = 正數 d 에 対応하는

順位番号의 合計

H_1 : 負數 d 에 対応하는 順位番号의 合計 $\asymp$ 正數 d 에 对应하는 順位番号의 合計

위의 表에 의하면 - 符号의 合計値가 4, + 符号의 合計値가 32 로 되어 있다. 그런데 이때의 合計値가 작은 것, 즉 4 가 檢定統計量 T 로 된다. 아래 表에 의하면 $n=8$ 일 때 5% 有意水準下에서의 값은 2 로 되어 있다. 그런데 t-檢定の 경우

順位의 合에 의한 檢定表

합이 이들값과 같거나 작을때 기각한다 <兩側檢定用>

標本の 크기	5 % 水準	1 % 水準
7	2 (.047)	0 (.016)
8	2 (.024)	0 (.008)
9	6 (.054)	2 (.009)
10	8 (.049)	3 (.010)
11	11 (.053)	5 (.009)
12	14 (.054)	7 (.009)
13	17 (.050)	10 (.010)
14	21 (.054)	13 (.011)
15	25 (.054)	16 (.010)
16	29 (.053)	19 (.009)

※ 괄호안의 숫자는 正確한 有意水準값을 나타낸다.

와는 달리 여기에서는 計算한 檢定統計量 T 의 값이 위표의 값과 같거나 이보다 작을 때 假定을 기각하게 된다. 따라서 이 경우는 5% 有意水準下에서 假說은 기각되지 않는다.

이와 같은 問題에서 각 짝의 測定値差의 絶對值 중에서 같은 것이 있을 수 있음은 勿論이다. 例를 들면 위의 例에서 첫째 짝의 差의 값이 13이라면 順位 6의 差와 같게 된다. 이와 같은 경우 6, 7번이라는 番号대신에 6.5, 6.5와 같은 번호값을 使用하게 된다. 또 差의 값이 0일 때는 이 짝을 除外하고 番号를 붙인다. 앞의 例에서 두번째 짝의 差가 0이라고 하면 이것을 除外하고 7번까지만 番号를 붙인다. 즉 이때는 $n=8$ 이 아니라 $n=7$ 로 되는 것이다. 또 標本의 크기 n 이 16以上일 때는 檢定統計量 T 가 近似的으로 正規分布를 한다는 것을 利用한다. 即

$$Z = (|\mu - T| - \frac{1}{2}) / \sigma$$

로 놓으면 Z 는 近似的으로 標準正規分布에 따른다는 것이다. 단, 위의 式에서 $\mu = n(n+1)/4$, $\sigma = \sqrt{(2n+1)\mu/6}$ 이다.

3.4 Bayesian 意思決定論

(1) 緒 論

意思決定論者 그 중에서도 특히 Bayesian 意思決定論을 다루는 사람들은 前小節에서 說明한 종래의 統計的 方法을 古典的

인 方法이라고 하여 意思決定論的 方法과 구별한다. 그런데 이 두가지 方法은 使用하는 用語에 있어서는 다른 點이 많은 反面에, 問題를 다루는데 있어서는 分析方法에 있어서는 유사한 點이 많은 것이 사실이므로 古典的 方法과 比較하면서 說明하기로 하자.

위에서 말한 差異點과 類似點을 다음과 같은 假說檢定問題에서 찾아보는 것이 편리할 것이다. 生産品의 不良率 P 에 관하여 帰無假說 $H_0 : P \leq P_0$ 을, 對立假說 $H_1 : P > P_0$ 에 대하여 檢定하는 경우를 생각해 보기로 한다. 古典的인 統計的 方法에서는 우선 生産品集團에서 標本을 취하여 그 중에서의 不良品數를 조사하고, 이것을 基礎로 하여 위에서 세운 帰無假說 H_0 를 受落할 것인가, 기각할 것인가 하는 意思決定規則을 만들어 낸다. 이와 같은 경우 第1種의 過誤의 確率의 最大限度로서 α 를 定하고, 또 對立假說 H_1 내에서의 P 값에 대한 第2種의 過誤를 범하게 되는 確率을 따지게 된다. 이와 같은 것은 다음表 3.4.1에 整理해 놓은 바와 같이 우리가 세운 假說은 自然의 狀態에 대하여 記述한 것이고, H_0 를 受落 또는 棄却하는 것은 우리의 行爲로서 A_1 , 또는 A_2 와 같이 表記할 수가 있을 것이다. 이와 같은 対応은 古典

表 3.4.1 古典的인 統計的 檢定과 意思決定論에서의 行爲

假設 : 自然狀態	行爲 A_1 : H_0 를 受落	行爲 A_2 : H_0 를 기각
H_0 가 真이다	過誤 없음	第1種의 過誤
H_1 이 真이다	第2種의 過誤	過誤 없음

的인 統計的 方法과 意思決定論과의 類似點을 表示한다. 더구나 이 問題에 대하여 表 3.4.2와 같은 損失表를 作成해 보면 이러한 類似點은 더욱 明瞭해 진다. 이 表에서 θ_1 下에서의 行爲 A_2 의 機會損失을 $L(A_2/\theta_1)$ 로 表示하고, θ_2 下에서의 行爲 A_1 의 機會損失을 $L(A_1/\theta_2)$ 로 나타낸 것이다.

表 3.4.2 損 失 表

自然의 狀態	行 為	
	A_1	A_2
θ_1	0	$L(A_2/\theta_1)$
θ_2	$L(A_1/\theta_2)$	0

이제 두가지 方法間의 差異點을 생각해 보기로 한다. 假說檢定에 있어서는 有意水準 α 의 選擇이 意思決定方法을 決定짓게 되어 있어, 對立假說중에서의 選擇의 여지가 없게끔 만들어진 것이 特色이다. 즉 이것을 記号로 表示하면 $\alpha = P(A_2/H_0 \text{가 真})$ 인 것에서 알 수가 있다. 따라서 假說檢定에 있어서의 行爲間에서의 選擇에 대한 주된 判定基準은 이와 같은 型의 誤差가 일어나는 相對頻度이다. 그러면 有意水準 α 는 어떻게 選定되는가? 많은 應用例에서 편의상으로 α 로서 0.05 또는 0.01를 採하게 되는데, 이러한 경우 問題로 하고 있는 對象에 따라서 어떤 特別한 고려없이 一律적으로 α 값이 選定되는 경향이 있다. 그러나 이와 같은 傾向은 假說檢定方法 그 자체의 欠點은 아니다. 이것은 이 方法을 利用하는 사람들의 잘못에 지나지 않으며, 우리는 假說檢定

에 있어서 그 対象에 대한 專門的인 知識을 活用하여 帰無假說과 対立假說의 設定에 세심하여야 하며, α 의 選定에 있어서 여러가지로 주의 깊은 考察을 하여야 될 것이다. 그런데 바로 이러한 점이 Bayesian 意思決定論의 추종자들에 의해서 批判을 받는 点이다. 그들은 假說檢定이 根拠없는 主觀과 判定에 의하여 實施되고 있다고 비난한다. Bayesian 統計學者들은 그들의 意思決定節次가 合理的인 假說檢定方法을 論理的으로 發展시킨 것이라고 主張하고 있다. 그들은 自然의 狀態(위의 경우는 帰無假說과 対立假說)에 대하여 事前確率分布를 부여하고, 그들의 判定에 따르는 損失을 고려하여 意思決定을 한다는 것이다.

(2) 假說檢定과 두 行爲問題와의 比較

意思決定을 하는 데 있어서 古典的인 方法과 Bayesian 方法과의 比較를 두 行爲問題로 說明해 보기로 한다. 한 輸入業者가 어떤 物品을 輸入하는데 있어서, 対象者는 이름과 住所가 收錄되어 있는 10,000 名이다. 이와 같은 경우 輸入業者의 가능한 두 行爲는

A_1 : 物品을 輸入하여 市販한다.

A_2 : 輸入하지 않는다.

여기에서 P 를 輸入品을 注文購入하게 될 比率(10,000 名중에서의 比率)을 表示하는 것으로 한다. 따라서 이때 注文購入者의 比率 P 가 0.05 보다 작을 때는 輸入하지 않기로 意思決定을 하게

된다. 이때 損失表는 다음과 같다고 하자.

表 3.4.3 損 失 表 (単位 : ₩ 1,000)

事 件	行 為	
	A_1	A_2
$P \leq 0.05$	₩ 20,000(0.05-P)	0
$P > 0.05$	0	₩ 20,000(P-0.05)

注文購入할 사람 數의 比率을 알기 위하여 명부에서 100 名을 임의로 抽出하여 輸入한 物品의 廣告를 보내어, 그 反應에 따라서 標本比率 $\hat{P}$ 를 計算하고, 이것으로 P 값을 推測하는 方法을 생각한 다.

이때 古典的인 統計的 方法에서의 檢定法은 標本比率 $\hat{P}$ 를 利用 하여, $H_0 : \hat{P} \leq 0.05$ 를 $H_1 : P > 0.05$ 에 대하여 다음과 같이 한 다. 즉 H_0 下에서 標本比率 $\hat{P}$ 의 標準誤差 $\sigma_{\hat{P}}$ 를

$$\sigma_{\hat{P}} = \sqrt{\frac{pq}{n}} = \sqrt{\frac{(0.05)(0.95)}{100}} = 0.0218$$

과 같이 計算하고, $Z = (\hat{p} - 0.05) / \sigma_{\hat{P}}$ 가 標準正規分布에 따른다 는 것을 利用한다. $\alpha = 0.05$ 로 하였을 때, $Z = 1.65$ 이므로

$$\hat{P} > 0.05 + (1.65)(0.0218) = 0.086$$

일 때는 有意水準 $\alpha = 0.05$ 下에서 H_0 를 棄却하게 되는 것이다.

이 問題에서 比率 $\hat{P}$ 대신에 注文購入 하겠다는 사람數 x 를 가 지고 表現하면 $100(0.086) = 9$ 이므로

- ① $x > 9$ 일 때는 H_0 를 棄却한다. (輸入販売한다)

② $x \leq 9$ 일 때는 H_0 를 受落한다 (輸入販売하지 않는다)

이와 같은 경우 $\alpha = 0.05$ 라고 하는 것은 確率記号로 表示하여

$$P(x > 9 | p \leq 0.05) = 0.05$$

라고 하는 것을 뜻한다. 이때의 第2種의 過誤는 $P(x \leq 9 | p > 0.05)$ 와 같이 表現된다.

假說檢定の 方法에 따라 意思決定을 하는 데 있어서 좋은 意思決定規則 (위의 例에서는 “ $x > 9$ 일 때는 H_0 를 棄却한다”는 것이 意思決定規則이다)은 第1種의 過誤가 작고, 또 第2種의 過誤도 작은 것이어야 된다는 것은 理解하기는 어렵지 않을 것이다. 그러면 여기에서 第1種의 過誤와 第2種의 過誤가 서로 어떤 關係에 있는가 하는 것을 알아보기 위하여 다음과 같은 세가지 意思決定規則을 비교하여 보기로 한다.

① $x > 2$ 일 때 H_0 를 棄却한다.

② $x > 7$ 일 때 H_0 를 棄却한다.

③ $x > 9$ 일 때 H_0 를 棄却한다.

이와 같은 세가지 意思決定規則 (檢定節次)에 대하여 各各의 第1種의 過誤와 第2種의 過誤를 圖表로 나타낸 것이 그림 3.4.1이다.

이 圖表에서 알수 있는 것은 第一種의 過誤가 큰 意思決定規則은 第2種의 過誤가 작고, 반대로 第1種의 過誤가 작은 것에 있어서는 第2種의 過誤가 크게 된다는 事實이다. 이러한 現象으




그림 3.4.1 誤差特性曲線

로 보아서 좋은 意思決定規則을 選定한다는 것이 얼마나 어려운 것인가 하는 것을 짐작할 수가 있을 것이다.

이제 이와 같은 問題가 Bayesian 意思決定節次에서는 어떻게 解決되는가를 알아 보기로 한다. 우선 圖 3.4.1 에서 $P = 0.02, 0.04, 0.06, 0.08$ 의 경우에 대하여, 各各에 대한 α 값을 表示한 表 (3.4.4) 를 作成하여 두는 것이 必要할 것이다.

表 3.4.4 $H_0 : P \leq .05$ 에 對한 α 값

P	意 思 決 定 規 則		
	$x > 2$	$x > 7$	$x > 9$
0.02	0.5000	0.0002	0.0000
0.04	0.3461	0.0571	0.0054
0.06	0.9545	0.3372	0.1020
0.08	0.9864	0.6443	0.8557

이 表 3.4.4 와 損失表 3.4.2 를 利用하여 $x > 2$ 와 같은 意思決定規則을 使用할 경우, 自然의 狀態가 $P = 0.02$ 일 때, 期待機會損失額數를 計算하면 다음과 같이 된다.

表 3.4.4 에 의하면 $P(H_0 \text{를 棄却} | P = 0.02) = 0.5$, $P(H_0 \text{를 受落} | P = 0.02) = 0.5$ 이고 $P = 0.02$ 일 때의 機會損失은 損失表 3.4.2에서 行為 A_1 을 취하였을 때 (H_0 를 棄却하였을 때) ₩ 20,000,000 ($0.05 - 0.02$) = ₩ 600,000 이고 行為 A_2 를 취하였을 때 (H_0 를 受落하였을 때) ₩ 0이다. 따라서 이때의 $P = 0.02$ 라는 條件下에서의 期待機會損失値는 다음과 같이 計算된다.

行 為	$P(A_i)$	機會損失	期待機會損失
A_1	0.5	₩ 600,000	₩ 300,000
A_2	0.5	0	0
			300,000

$P = 0.04$ 일 때의 行為 A_1 에 대한 機會損失値는 ₩ 20,000,000 ($0.05 - 0.04$) = ₩ 200,000 이므로, 表 3.4.4 를 利用하여, $P = 0.04$ 라고 하는 條件下에서의 期待機會損失値는 다음과 같다.

行 為	$P(A_i)$	機會損失	期待機會損失
A_1	0.8461	₩ 200,000	₩ 169,220
A_2	0.1539	0	0
			₩ 169,220

그러나 $P = 0.06$ 일 때는 損失表 3.4.3 에서 알 수 있는 바와 같이 行為 A_1 에 따르는 機會損失은 ₩ 0 이고, 行為 A_2 에 따르는 機會損失은 ₩ 20,000,000 ($0.06 - 0.05$) = ₩ 200,000 이므로 表 3.4.4 를 利用하여 이때 條件附 期待機會損失은 다음과 같이 計算된다.

行 為	$P(A_i)$	機會損失	期待機會損失
A_1	0.9545	0	0
A_2	0.0455	₩ 200,000	₩ 9,100
			₩ 9,100

마찬가지로 $P = 0.08$ 에 대한 條件附 期待機會損失值를 計算하면 ₩ 8,160 으로 된다. 以上の 것을 整理하여 表 3.4.5 를 얻는다.
表 3.4.5 $H_0 : P = 0.02$ 일 때의 意思決定規則 $x > 2$ 에 대한

期待機會損失值

自然의 狀態 P	條件附 期待機會損失值
0.02	₩ 300,000
0.04	169,220
0.05	0
0.06	9,100
0.08	8,160

이와 같은 것을 다른 意思決定規則 $x > 7$, $x > 9$ 에 대하여, 위
 表와 같이 整理하면 다음과 같이 된다.

表 3.4.6 세 가지 意思決定規則에 대한 條件附 期待機會損失值

自然의 狀態 P	意 思 決 定 規 則		
	$x > 2$	$x > 7$	$x > 9$
0.02	₩ 300,000	₩ 120	₩ 0
0.04	169,220	11,420	1,080
0.06	9,100	132,560	179,600
0.08	8,160	213,420	386,580

條件附 期待損失值는 $P \leq 0.05$ 일 때는 第 1 種의 過誤
 로 인한 損失을, $P > 0.05$ 일 때는 第 2 種의 過誤로 인한 損失을
 金額值로 表示한 것이라고 할 수가 있다. 그러므로 以上에서의
 考察은 古典的인 假說檢定 方法에 의한 意思決定節次를 “損失”
 이라고 하는 概念으로 表現하였을 뿐이므로, 本質的으로 Bayesian
 方法의 差異點을 나타내는 것이라고는 할 수 없다. 여기에서
 Bayesian 統計學者들은 2.4 節에서 설명된 바와 같이 自然의 狀
 態 P 의 여러가지 값에 대하여 그 事前確率 $P_0(P)$ 를 부여한다.

P	$P_0(P)$
0.02	0.10
0.04	0.40
0.06	0.45
0.08	0.05

即, 이와 같은 事前確率을 利用하여 意思決定規則 $x > 2$ 에 대한 無條件 期待機會損失值를 計算하면 다음과 같이 된다.

表 3.4.7 $x > 2$ 에 대한 無條件期待機會損失值

$P_0(P)$	條件附期待值	期 待 值
0.10	₩ 300,000	₩ 30,000
0.40	169,220	67,688
0.45	9,100	4,095
0.05	8,160	408
		₩ 102,191

마찬가지로 다른 意思決定規則 $x > 7$, $x > 9$ 에 대하여 無條件 期待機會損失을 計算하여 위의 結果와 같이 정리하면 다음과 같이 된다.

表 3.4.8 $x > 2$, $x > 7$, $x > 9$ 에 대한 無條件 期待機會損失值

$P_0(P)$	$x > 2$	$x > 7$	$x > 9$
0.10	₩ 30,000	₩ 10	₩ 0
0.40	67,690	4,570	430
0.45	4,100	59,650	80,820
0.05	410	10,670	19,330
	₩ 102,200	₩ 74,900	₩ 100,580

이와 같은 方法에 의하면 세가지 意思決定規則에서 期待損失이 작은 것 即 $x > 7$ 을 選擇할 수 있게 된다. 이와 같이 하는 것이 Bayesian 統計的 方法인 것이다.

第 4 章 相 關 과 回 歸

4.1 相關分析

우리들 日常生活에서 나타나는 經濟的이고 自然的인 모든 現象은 統計的 觀點에서 본다면 하나의 時系列로 表現될 수 있으며, 그 時系列은 다른 現象의 時系列과의 사이에 하나의 聯関性 (relationship)이 있는 것으로 생각할 수 있다.

即 工場勞動者の 賃金과 年齡사이의 관계나 洋品店에 있어서의 雨傘과 日氣사이에는 相互依存的인 立場에 놓이게 되는 것을 알 수 있다. 따라서 所得이 낮은 사람은 밍크 코우트를 購入할 수없는 反面, 財産이 많은 사람은 所得以上으로 衣服을 購入할 수도 있다.

이와 같은 相互依存關係는 칼·피어슨 (K. Pearson)의 生物測定에서 發展시킨 方法論이며, 이러한 方法에 의하여 얻어지는 情報은 經濟豫測과 政策樹立에 매우 価値있는 것으로 評價되기도 한다.

따라서 서로 対応하는 時系列의 統計量을

$$x_i \quad (i = 1, 2, \dots, n)$$

$$y_j \quad (j = 1, 2, \dots, n)$$

로 表示하고 x 의 값이 決定될 때 y 의 값이 決定된다면 이 두 統計量사이의 關係는

$$y = f(x)$$

라는 函数的 關係로 把握되며 이와 같은 相互聯関性을 相関關係 (correlation) 로 認識하는 것이다.

(A) 相関의 数学的 說明

이와 같은 函数的 表示는

① x 가 增加함에 따라 y 도 - 增加하는 경우

② x 가 增加함에 따라 y 는 減少하는 경우와

③ x 의 變化에 比例하여 y 가 增加하던지 減少하는 경우

④ 두 變量이 같은 方向이나 反對方向으로 變化하는 傾向이 전혀 나타나지 않은 경우를 들 수 있는 바, 여기에 대하여는

数学的 用語를 使用하여 ① 正相関 ② 負相関 ③ 完全相関 ④ 無相関

이라고 한다.

(B) 相関表의 作成

앞에서 言及한 바와 같이 變量 x 의 變化에 따라 變量 y 가 變化할 때 이를 說明하는 度数分布表를 相関表(correlation table) 라고 하는바 다음과 같은 例가 이를 理解할 수 있게 할 것이다.

即 다음의 表 4.1.1 은 H洋服店の 3年間に 걸친 期別 資料이다. 이 資料를 가로에는 顧客에 대한 度数分布表로서, 세로에는 売上高에 대한 度数分布表를 作成하여 하나의 箱子모양의 度数記入欄에 度数(該当期數)를 記入하면 一般的으로 表 4.1.2 와 같이 左上에서 右下로 연결되는 對角線에 모이게 되는 特質을 가지고

表 4.1.1

두 變 量 의 關 係

期 別	顧 客	売 上 高
1969 / 1	750	268.5 (萬 원)
2	700	240.0
3	850	296.0
4	980	312.2
'70 / 1	1,000	328.5
2	900	285.5
3	660	225.0
4	790	274.5
'71 / 1	1,040	309.3
2	920	307.6
3	730	256.7
4	900	315.1

있는 바 이는 두 變 量 사이에 依存性이 높으면 높을수록 完全對角線을 이루게 된다는 것을 說明한다.

一般的으로 顧客을 x_i , 売上高를 y_i 로 文字化 했을 때, 變 量 x_i 를 基準으로 했을 때의 度数의 合計 g_i 와 變 量 y_i 를 基準으로 했을 때의 度数의 合計 n_j 에 의한 다음과 같은 定式을 얻을 수 있다.

$$g_i = f_{i1} + f_{i2} + \dots + f_{in} = \sum_{j=1}^n f_{ij}$$

$$n_j = f_{1j} + f_{2j} + \dots + f_{nj} = \sum_{i=1}^m f_{ij}$$

表 4.1.2 相 関 表 (顧 客 과 売 上 高)

顧客 売上高 x y		600 ~ 700	700 ~ 800	800 ~ 900	900 ~ 1000	1000 ~ 1100	計
		650	750	850	950	1,050	
210 ~ 230	220	1					1
230 ~ 250	240	1					1
250 ~ 270	260		2				2
270 ~ 290	280		1	1			2
290 ~ 310	300			1	1	1	3
310 ~ 330	320			1	2		3
計		2	3	3	3	1	12

또한 이와 같은 相関表에 의하여 그래프를 作成할 때에는 直角座標面에 1개 내지 몇 개의 点에 의하여 表示되는 点相関圖 (Scatter diagram)를 作成할 수 있는 것도 아울러 일러둔다.

(1) 相関關係의 測定

우리는 相関圖를 作成함으로써 두 變量間의 相互依存關係가 어느 程度인가를 대개 把握할 수 있는 바, 이와 같은 性質의 尺度를 相関係數 (Coefficient of Correlation)라 한다.


(A) 相関係數의 測定式 導出

따라서 이러한 相互依存性을 하나의 係數로 表示하기 위한 定式을 마련하기 위하여 다음과 같은 說明을 必要로 하게 된다.

即 다음의 도표 4.1.1에서와 같이 각 点은 새로운 座標軸

x, y 에 의하여 4 상한으로 分割되어지므로 x_i, y_i 에 대한 各 상한의 總和 S 를 생각해 보면,

圖 4.1.1 軸의 變換



$$S = \sum_1 x_i y_i + \sum_2 x_i y_i + \sum_3 x_i y_i + \sum_4 x_i y_i \quad \text{--- (1)}$$

(I) (II) (III) (IV)

가 되며 S 의 符号는 各 상한의 散布度 (dispersion)를 測定하
므로써 쉽게 判斷할 수 있다. 이와 같이 x_i, y_i 의 總和 S 를
測定하면 相關의 程度를 推測할 수 있는 데 相關係數란 이 總和의
平均을 標準化함으로써 얻어질 수 있는 것이다. 다시 말하면 이
렇게 하여 얻어진 共分散 (Co-Variance)

$$\frac{S}{n} = \frac{1}{n} \sum x_i y_i = \frac{1}{n} \sum (X_a - \bar{X})(Y_j - \bar{Y}) \quad \text{--- (2)}$$

를 標準偏差 $\sigma x, \sigma y$ 로 나누어 줌으로써 標準化가 이루어 진다.

따라서 우리가求하고자 하는 相關係數 r 은

$$r = \frac{\sum (X_i - \bar{X})(Y_j - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_j - \bar{Y})^2}} \quad (3)$$

가 되며 이를 偏差平方和을 求할 必要가 없는 다음과 같은 方法으로도 使用할 수 있다.

$$r = \frac{\sum X_i Y_j - \frac{1}{n} \sum X_i \sum Y_j}{\sqrt{\sum X_i^2 - \frac{1}{n} (\sum X_i)^2} \sqrt{\sum Y_j^2 - \frac{1}{n} (\sum Y_j)^2}} = \frac{\sigma_{xy}}{\sigma_x \sigma_y}$$

여기에서 알아둘 것은 (1) (2) (3) 式에 있어서 使用되는 添數記號 i 와 j 는 두 變量의 個수가 같은 경우 i 로 統一 使用할 수 있으며 이 경우의 (3) 式은 다음과 같이 表記되어 진다.

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

(B) 相關係數의 決定

이와 같은 相關係數의 範圍는,

$$+1 \geq r \geq -1$$

이 된다. 따라서 r 의 絶對值가 갖는 값에 따라 相互依存的인 聯關의 程度를 알 수 있는 바, 相關程度의 強弱은 變量 間의 因果關係가 分明히 成立한다고 認定되는 經驗的이고 實證的인 檢證이 前提로 되었을 때에 局限하여 使用되어야 한다는 點을 附記한다.

一般的으로

① $|r| < 0.3$ 이면 依存關係가 거의 없다.

② $0.3 < |r| \leq 0.5$ 이면 依存關係가 약간 있다.

③ $0.5 < |r| \leq 0.7$ 이면 依存關係가 確實히 存在한다.

④ $0.9 < |r|$ 이면 強한 依存關係가 있다.

라고 說明하고 있는 데 ③의 경우 相關係수가 0.7 程度이면 依存關係가 分明하다고 하는 說明은 決定係數 ($R = r^2$) 理論에서 $r^2 \geq 0.5$ 의 性格이 이를 說明하고 있다.

(C) 相關關係의 測定

時系列 相關을 測定하는 데 있어서는 經濟的 意味가 갖는 變量의 相互依存關係에 따라 同時相關과 時差相關의 두가지 測定方法이 있다.

지금 두개의 時系列資料에서 나타난 變量을 X_t, Y_t 라고 하면,

$r(X_t, Y_t)$ X와 Y의 同時相關

$r(X_t, Y_{t-k})$ X와 K時点 前の Y와의 時差相關

$r(X_{t-k}, Y_t)$ Y와 K時点 前の X와의 時差相關

으로 表現할 수 있으며 說明의 便宜를 위하여 同時相關의 測定을 하여 보면 表 4.1.3 과 같은 計算方法에 의하여

$$\sigma_x = \sqrt{14,288} = 119.4$$

$$\sigma_y = \sqrt{964.07} = 31.0$$

$$\sigma_{xy} = 3,349.4$$

이므로 相關係數 r 는

$$r = \frac{3,349.4}{119.4 \times 31.0} = 0.90$$

表 4.1.3 . 相 関 係 数 의 計 算

	x	y	$x_i - \bar{X}$	$y_i - \bar{Y}$	$(x_i - \bar{X}) \times (y_i - \bar{Y})$	$(x_i - \bar{X})^2$	$(y_i - \bar{Y})^2$
1	750	268.5	- 101	- 16.4	1,656.4	10,201	268.96
2	700	240.0	- 151	- 44.9	6,779.9	22,761	2,016.01
3	850	296.0	- 1	11.1	- 11.1	1	123.21
4	980	312.2	129	27.3	3,521.7	16,641	745.29
5	1,000	328.5	149	43.6	6,496.4	22,201	1,900.96
6	900	285.5	49	0.6	29.4	2,401	0.36
7	660	225.0	- 191	- 59.6	11,340.9	36,481	3,588.01
8	790	274.5	61	- 10.4	- 634.4	3,721	108.16
9	1,040	309.3	189	24.4	4,611.6	35,721	595.36
10	920	307.6	69	22.7	1,566.3	4,761	515.29
11	730	256.7	- 119	- 28.2	3,355.8	14,161	795.24
12	900	315.1	49	30.2	1,479.8	2,401	912.04
計	10,220	3,418.9			40,192.7	171,452	11,568.89
平 均	851	284.9			3,349.4	14,288	964.07

이 되어 두 變量사이에 있어서의 相互依存關係가 強하게 나타나고 있음을 알 수 있다.

(2) 相関係数の 検定

앞에서도 言及한 바와 같이 相関係数の 使用은 実証的이고 分析的인 檢証에 依하여서만 可能하므로 여기에서 相関係数の 檢定을 必要로 한다.

지금 붉은 주사위와 푸른 주사위를 다섯번 던져 다음과 같이 나왔다고 하자.

붉은주사위	푸른주사위
1	2
4	6
5	4
6	4
2	2

이와 같은 두개의 統計量에 의한 相関係數 r 의 計算에서 0.67을 얻었다고 하면 이 두 統計量 사이에 相互依存性이 存在한다고 할 수 있을 것인가의 問題가 提起되며 이 相関係數의 信賴度를 檢定해야 한다.

一般的으로 母集團 相関係數 ρ 와 n 개의 標本에서 얻은 標本 相関係數 r 사이에 있어서

$$t_r = \frac{1}{2} \log \frac{1+r}{1-r}$$

의 t 分布를 利用하게 되는 데 이는 正規分布 $N(\mu, \sigma^2)$ 와 近似하게 나타나는 바 이라고 놓으면 $\log$ 가 常用對數로 바뀌어져야

$$\mu = \frac{1}{2} \log_e \frac{1+\rho}{1-\rho} \quad \sigma^2 = \frac{1}{n-3}$$

하므로,

$$tr = \frac{1}{2} \log_e \frac{1+r}{1-r} = 1.1513 \log_{10} \frac{1+r}{1-r} \quad (5)$$

$$\mu = \frac{1}{2} \log_e \frac{1+\rho}{1-\rho} = 1.1513 \log_{10} \frac{1+\rho}{1-\rho}$$

로 사용되며 만일 母集團 相關係數 ρ 가 ρ_0 에 같다고 하면
假說 $H_0: \rho = \rho_0$ 가 되어서 이에 의하여 假說檢定하게 된다.

그러나 tr 가 $N(\mu, 1/n-3)$ 으로 나타낼 수 있다는 前提
아래,

$$t = (tr - \mu_0) \sqrt{n-3} \quad (6)$$

을 計算하는 한편 正規分布의 有意水準 α 点의 t_α 를 求하여 보
면 다음과 같은 檢定이 可能해 진다.

① $|t| > t_\alpha$ 이면 H_0 를 棄却

② $|t| \leq t_\alpha$ 이면 H_0 를 採択

예를 들어 H大学 校의 統計学科 學生 88 名에 대한 IQ와 数学
成績과의 相關係數는 0.69 이고 1 年前의 相關係數는 0.75 였다면
이 두 現象에 대한 信賴度는 어떠한가에 대하여 檢討해야 한다.

이 경우 $n = 88$ $r = 0.69$ $\rho_0 = 0.75$ 이므로 假說로서 $\rho =$
 ρ_0 가 認定되어야 하며 (5) 式에 의하여,

$$t_r = 1.1513 \log_{10} \frac{1 + 0.69}{1 - 0.69} = 0.843$$

$$\mu_o = 1.1513 \log_{10} \frac{1 + 0.75}{1 - 0.75} = 0.973$$

을 얻고 (6)式에 의하여

$$t = (0.843 - 0.973) \sqrt{88-3} = -1.199$$

를 얻게 되므로 有意水準 5%인 點은,

$$t_{0.05} = 1.96$$

$$|t| = 1.199 < 1.96 = t_{0.05}$$

가 되어 H_o 는 採択되어 두 相關係數는 같은 것으로 判斷되어
지는 것이다.

以上과 같은 相關關係는 經濟的이고 經營的인 現象에 대한 統計
的 分析에 많이 適用되는 方法으로 이러한 變量 間의 關係는 單
純히 相關係數의 測定으로 그치는 것이 아니라 回歸分析이라는 方
法과 結合하여 定量的인 相互依存關係를 說明해 나갈 때 企業의
成長이나 經濟全般的인 與件의 變動, 그리고 生産品에 대한 市場
性的 檢討와 같은 社會科學 全般에 걸친 內容과 教育水準의 測定
이나 生物遺傳의 分析的 方法에도 널리 利用되고 있다는 것을 알
아야 하겠다.

4.2 回帰分析

変量 x 를 原因 또는 独立変数, y 를 結果 또는 従属変数라고 하면 2變量の 關係는 一般的으로 다음과 같이 表示할 수가 있다.

$$y = f(x)$$

x 에 대한 y 의 變化가 어느 정도 規則적으로 일어나는 경우에는 이 函数는 比較的 간단한 数学式으로 表示된다. 가장 간단한 것은 一次直線이다.

$$y = a + bx$$

統計의 問題는 實際의 觀察에서 얻어진 2變量 x, y 의 關係를 이러한 数学式으로 表現하는 것이다. 이러한 變量사이의 關係를 表示하는 方程式을 回帰方程式 (regression equation)이라 한다.

이 方程式이 그리는 線을 回帰線 (regression line)이라 하는 바 그것이 直線인 경우에는 直線回帰라 하고 曲線인 경우에는 非直線回帰라 한다.

(1) 直線回帰

回帰直線은 $y = a + bx$ 로 表示할 수가 있다. a 는 $x = 0$ 일 때의 截片이고 b 는 이 直線의 方向係数이다. 이 a, b 는 直線의 位置와 方向을 決定하는 數値로서 直線의 方向係数 b 를 x 에 대한 y 의 回帰係数라고 한다. 回帰分析에 있어서는 關係變量 x, y 의 觀察値에서 a, b 등의 값을 計算하는 것이 問題가 된다.

a, b 의 값이 결정되면 원인 변수 x 의 값이 주어지면 변수 y 의 값은 회귀方程式에서 곧 결정할 수가 있다.


따라서 회귀方程式은 변수 y 의 값을推定하는式이라고 생각할 수 있다.

身長과體重, 남편의結婚年齡과 아내의結婚年齡사이에는 거의 직선적인函数關係를 보인다. 예컨대 表 4.2.1을 点散圖로表示한 4.2.1圖에서 보는 바와 같이 남편의年齡이 많아짐에 따라 아내의年齡도 그에 상응하여 많아져 가고 있다. 이 点의連續에 가장 適合한 直線을 긋는 것이 回歸分析의 問題이지만 觀察値와 回歸直線과의 距離 d 의 自乘의 合計를 最小로 하는 直線은 2線밖에 없다. 여기에 2線이란 하나는 x 에 대한 y 의 回歸線이고 다른 하나는 y 에 대한 x 의 回歸線이다.

表 4.2.1 夫婦의 結婚年齡

男便(x)	24	26	28	30	32	34	36	38	40	42
아내(y)	21	20	24	27	28	29	33	28	37	33

圖 4.2.1 夫婦의 結婚年齡



이 2개의 回歸線은 圖 4.2.2에서 보는 바와 같이 다른 것이 보통이고 다만 2系列 사이에 完全한 函數關係가 있을때에 한해서 일치 된다.

回歸直線의 方程式 $y' = a + bx$ 로 表示되므로 最小自乘法에 있어서 問題가 되는 것은 傾向線의 計算의 경우와 마찬가지로,

$$\sum d^2 = \sum (y - y')^2 = \sum (y - a - bx)^2$$

의 값을 最小가 되도록 方程式의 定數를 定하는 것이다. 定數 a, b 는 다음과 같은 正規方程式에 (normal equation) 주어진 資料를 대입함으로써 計算된다.

$$\sum y = na + b\sum x$$

$$\sum xy = a\sum x + b\sum x^2$$

여기서 n 은 變量 x, y 의 觀察數를 가리킨다.

定數 a, b 는 또한 正規方程式에서 구해진다,

$$a = \frac{\sum x^2 \sum y - \sum x \sum xy}{n \sum x^2 - (\sum x)^2}$$

$$b = \frac{n \sum xy - \sum x \sum y}{n \sum x^2 - (\sum x)^2}$$

에 의하여 決定할 수도 있다. 여기서 b 가 回歸係數인 것이나 이것은 또한 $\bar{x}, \bar{y}$ 를 각각 x, y 의 平均値라 할때 다음과 같이 表示할 수가 있다.

$$b = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sum (x - \bar{x})^2}$$

表 4.2.1에 대한 回歸方程式을 구하면 다음과 같다.

男便의 年齡을 x , 아내의 年齡을 y 라 하면 回歸方程式은 다음 式으로 주어진다.

$$y' = a + bx$$




表 4.2.1에 대한 正規方程式은 表 4.2.3에 따라 다음과 같이 된다.

$$\begin{cases} 282 = 10a + 330b \\ 9,590 = 330a + 11,220b \end{cases}$$

이 方程式을 풀면

$$a = -0.18$$

$$b = 0.86$$

圖 4.2.2 2개의 回歸直線

이 된다. 따라서 구하는 回歸方程式은,

$$y' = -0.18 + 0.86x \quad (1)$$

가 된다. 이것은 x 에 대한 y 의 回歸方程式이다. 다른 하나의 回歸方程式 즉 y 에 대한 x 의 그것도 위와 마찬가지로 구해진다.

$$\Sigma x = na' + b'\Sigma y$$

$$\Sigma xy = a'\Sigma x + b'\Sigma y^2$$

$$\begin{cases} 330 = 10a' + 282b' \\ 9,590 = 282a' + 8,238b' \end{cases}$$

이 方程式을 풀면

$$a' = 4.96, \quad b' = 0.99$$

그러므로 구하는 回歸方程式은

$$x' = 4.96 + 0.99 y \quad (2)$$

가 된다.

表 4.2.3 直線回歸의 計算

x	y	xy	x^2	y^2
24	21	504	576	441
26	20	520	676	400
28	24	672	784	576
30	27	810	900	729
32	28	896	1,024	784
34	29	986	1,156	841
36	33	1,188	1,296	1,089
38	28	1,064	1,444	784
40	37	1,480	1,600	1,369
42	35	1,470	1,764	1,225
330	282	9,590	11,220	8,238

위의 回歸方程式에서 알 수 있듯이 이 양자는 서로 다르다.

예컨대 (1)식에 의하면 28 歳の 男便에 대한 아내의 理論的 年齡은 23.9 歲이지만 23.9 歳の 아내에 대한 男便의 理論的 年齡은 (2) 式에 의하여 28.6 歲가 되며 그 사이에 0.6 歲라는 差異가 생긴다. 이 差異는 x, y 中の 어느 하나가 獨立變量으로서 扱해

지며 어느 하나가 從屬變數로서 扱해 지느냐에 의한다. 즉 獨立變數로 간주된 系列은 올바른 것이라고 하고, 從屬變數로 看做로 系列에만 誤差가 생길 수 있다고 推定되어 있기 때문이다. 그러나 兩 系列사이에 完全한 函數關係가 있을 경우에는 이 2回歸線이 일치함은 물론이다.

回歸直線 $y' = a + bx$ 는 그것과 變量 y 와의 差의 自乘合이 最小가 되도록 그은 直線이다. 最小自乘法에 의해서 適用된 回歸直線은 이동하는 平均値의 線이라고 생각할 수가 있다. 그리고 平均値의 경우와 마찬가지로 回歸線에 대한 變量의 偏差의 合計는 언제나 0이 된다.

1 變量의 度数分布의 모양이 平均과 標準偏差에 의해서 代表되는 바와 같이 2 變量사이의 關係를 表示하는 경우에도 平均的인 關係를 表示하는 回歸線과 아울러 回歸線에 대한 變量의 變動幅을 생각할 必要가 있다. 回歸線에 대한 變量 y 의 標準偏差는 다음 式으로 주어진다.

$$S_y = \sqrt{\frac{\sum (y - y')^2}{n}}$$

또는,

$$S_y = \sqrt{\frac{\sum (y - a - bx)^2}{n}}$$

1 變量의 度数分布에서 分散度가 적을수록 平均은 變量全體를 잘 代表하는 것과 같이 回歸線에 대한 變量 y 의 分散이 적을수록

回帰線은 變量사이의 關係를 正確하게 代表한다. 따라서 이 경우에는 回帰方程式의 x 에 의해서 y 를 正確히 推定할 수가 있게 된다.

그러나 回帰線에 대한 變量 y 의 偏差가 標準偏差 S_y 의 3 倍 이상인 일은 거의 없다. 表 4.2.1 에서 回帰線에 대한 아래의 年齡의 標準偏差를 計算하면 다음과 같이 된다.

$$S_y = \sqrt{\frac{\sum (y - y')^2}{n}} = 2.03$$

表 4.2.4 回帰線에 대한 標準偏差

x	y	y'	$y - y'$	$(y - y')^2$
24	21	20.5	+ 0.5	0.25
26	20	22.2	- 2.2	4.84
28	24	23.9	+ 0.1	0.01
30	27	25.6	+ 1.4	1.96
32	28	27.3	+ 0.7	0.49
34	29	29.1	- 0.1	0.01
36	33	30.8	+ 2.2	4.84
38	28	32.5	- 4.5	20.25
40	37	34.2	+ 2.8	7.84
42	35	35.9	- 0.9	0.81
330	282			41.30

(2) 非直線回帰

男便의 年齡에 대한 아내의 年齡의 回帰線은 直線으로 表示되었지만 回帰線은 원래 相關函數의 각 座標點을 통하는 平均線인 만큼 만일 이 座標點이 曲線的으로 퍼져 있을 경우에는 이를 回帰曲線으로 表示할 必要가 있다. 이제 10 名의 社員의 入社試驗成績 x 와 이들에 대한 每月의 販賣成績 y 에 대해서 直線相關이 아니라 曲線相關 (Curvilinear Correlation)이 成立한다고 하면 回帰曲線은 다음과 같은 正規方程式을 利用하여 이를 計算할 수가 있다.

$$\sum y = na + b\sum x + c\sum x^2$$

$$\sum xy = a\sum x + b\sum x^2 + c\sum x^3$$

$$\sum x^2 y = a\sum x^2 + b\sum x^3 + c\sum x^4$$

表 4.2.5 入社試驗과 販賣成績

	A	B	C	D	E	F	G	H	I	J
入社試驗	4	5	6	4	5	6	6	7	9	8
販賣成績	5	4	5	6	9	10	9	12	11	9

만약에 x 가 1 連記号로 주어 졌을 경우에는 原点을 數列의 中央으로 옮기면 $\sum x = 0$, $\sum x^3 = 0$ 이 되어 위의 式은 다음과 같이 간단하게 된다.

$$\sum y = na + c\sum x^2$$

$$\sum xy = b\sum x^2$$

$$\sum x^2 y = a \sum x^2 + C \sum x^4$$

이 正規方程式을 풀면,

$$a = \frac{\sum y \sum x^4 - \sum x^2 \sum x^2 y}{n \sum x^4 - (\sum x^2)^2}$$

$$b = \frac{\sum xy}{\sum x^2}$$

$$c = \frac{n \sum x^2 y - \sum x^2 \sum y}{n \sum x^4 - (\sum x^2)^2}$$

가 된다. 따라서 이 경우에는 回歸曲線의 定數 a, b, c 의 計算은 매우 간단하게 된다.

曲線方程式은 一般的으로 整多項式的 形態로 주어진다. 즉,

$$y = a + bx + cx^2 + dx^3 + \dots$$

가 그것이다. 이 경우에는 더욱 自由로운 모양의 回歸線을 적합시킬 수가 있다. 일반적으로 k 次 整多項式은 $k-1$ 개의 커브를 갖는 曲線이 된다. 方程式의 定數 $a, b, c, \dots$ 는 傾向直線의 경우와 마찬가지로 最小自乘法에 의해서 變量 y 의 回歸線 y' 에 대한 偏差의 自乘合計

$$S = \sum \{ y - (a + bx + cx^2 + \dots) \}^2$$

이 最小로 되도록 정해진 다음과 같은 正規方程式에서 計算된다.

$$\sum y = na + b \sum x + c \sum x^2 + \dots$$

$$\sum xy = a \sum x + b \sum y^2 + c \sum x^3 + \dots$$

$$\sum x^2 y = a \sum x^2 + b \sum x^3 + c \sum x^4 + \dots$$

$a, b, c, \dots$ 의 값은 이와같이 連立方程式에 의해서 구해지는 것이나 回歸方程式이 k 次인 경우에는 正規方程式의 式數는 $k+1$ 개가 된다. 이는 구하고자 하는 定數의 數가 $k+1$ 개가 되기 때문이다. 連立方程式의 式數가 많아지면 方程式을 풀기가 어려워지지만 3次式 이상의 高次式을 回歸線으로 使用하는 경우는 별로 없다.


回歸曲線을 表 4.2.5에 구해 보면 다음과 같다.

表 4.2.6 回歸曲線의 計算

	x	y	xy	x^2y	x^2	x^3	x^4
A	4	5	20	80	16	64	256
B	5	4	20	100	25	125	625
C	6	5	30	180	36	216	1,296
D	4	6	24	96	16	64	256
E	5	9	45	225	25	125	625
F	6	10	60	360	36	216	1,296
G	6	9	54	324	36	216	1,296
H	7	12	84	588	49	343	2,401
I	9	11	99	891	81	729	6,561
J	8	9	72	576	64	512	4,096
合 計	60	80	508	3,420	384	2,610	18,708

$$\begin{cases} 80 = 10a + 60b + 384c \\ 508 = 60a + 384b + 2,610c \\ 3,420 = 384a + 2,610b + 18,708c \end{cases}$$

圖 4.2.3 回帰曲線에 대한 標準偏差



이 方程式을 풀면 $a = -4,631$, $b = 3,051$ $c = -0.148$

그러므로 回帰曲線은 $y' = -4,631 + 3,051x - 0.148x^2$ 으로
된다. 回帰曲線에 있어서도 直線의 경우와 마찬가지로 標準誤差

S_y 를 計算할 수가 있다.

表 4.2.5에 대해서 計算한 標準偏差는 다음과 같으며 $y' \pm S_y$ 를 圖示한 것이 圖 4.2.3이다.

$$\begin{aligned}
 S_y &= \sqrt{\frac{\sum (x - y')^2}{n}} \\
 &= \sqrt{\frac{\sum \{y - (-4,631 + 3,051x - 0.148x^2)\}^2}{10}} \\
 &= \sqrt{36,0311 / 10} = 1.9
 \end{aligned}$$

表 4.2.7 回歸曲線에 대한 標準偏差

	y	y'	$y - y'$	$(y - y')^2$	$y' - S_y$	$y' + S_y$
A	5	5.21	0.21	0.0441	3.31	7.11
B	4	6.92	2.92	8.5264	5.02	8.82
C	5	8.35	3.35	11.2225	6.45	10.25
D	6	5.21	0.79	0.6241	3.31	7.11
E	9	6.92	2.08	4.3264	5.02	8.82
F	10	8.35	1.65	2.7225	6.45	10.25
G	9	8.35	0.65	0.4225	6.45	10.25
H	12	9.47	2.53	6.4009	7.57	11.37
I	11	10.84	0.16	0.0256	8.94	12.74
J	9	10.31	1.31	1.7161	8.41	12.21
合 計	80			36.0311		

(3) 多元回帰分析

結果가 되는 從屬變數 y 에 대하여 原因이 되는 獨立變數는 x 하나만이 아니라 2개 이상 ($x_1, x_2, \dots$) 있는 것이 도리어 보통이다. 예컨대 賃金은 단순히 物価에 만 關係이 있는 데 그치지 않고 勞動態率, 勞動供給, 勞動立法, 企業利潤등과도 關係되어 있는 것이다.

따라서 이들 要素의 어느 것이 變化하면 賃金도 많던 적던 반드시 變化하게 마련이다. 結果變數 y 에 대하여 獨立變數 2개 이상을 생각하는 경우의 回帰分析을 多元回帰分析 (multi-variate regression analysis)이라 한다.


多元回帰의 경우에도 1變數回帰의 경우와 마찬가지로 從屬變數 y 에 대한 獨立變數 $x_1, x_2, \dots$ 의 關係는 直線인 경우도 있고 非直線인 경우도 있다.

獨立變數를 x_1, x_2 라 하면 回帰方程式은 直線의 경우에는 다음과 같이 된다.

$$y = a + b_1 x_1 + b_2 x_2$$

여기서 a, b_1, b_2 는 方程式의 定數이고 b_1, b_2 는 部分回帰係數 (partial regression coefficient)라는 것이다. b_1 은 變量 x_2 가 一定할 때 變量 x_1 의 變化로써 일어나는 y 의 變化를 나타내고 b_2 는 x_1 이 일정할 때 x_2 의 變化로써 일어나는 y 의 變化를 나타낸다.

圖 4.2.4 回 歸 平 面



獨立變數가 하나인 경

우의 回歸方程式

$y = a + bx$ 가 直線을

표示하는 것과 마찬가지로

로 獨立變數가 2개인

경우의 回歸方程式

$$y = a + b_1 x_1 + b_2 x_2$$

는 x_1, x_2, y 의 3軸으로

로 規定되는 하나의 3

次元의 空間에 있어서는 平面을 表示하고 있다. $x_1 = 0$ 일때

$y = a + b_2 x_2$ 는 $x_1 = 0$ ($y - x_2$ 平面)의 直線을 나타내고

$x_2 = 0$ 일 때 $y = a + b_1 x_1$ 은 $x_2 = 0$ ($y - x_1$ 平面)의 直線을

나타내며 또한 $y = 0$ 일 때 $a + b_1 x_1 + b_2 x_2 = 0$ 은 $x = 0$

($x_1 - x_2$ 平面) 위의 直線을 나타낸다.

이제 x_1, x_2, y 가 주어졌다면 이는 x_1, x_2, y 의 3軸으로

規定되는 空間의 1點을 나타낸다. x_1, x_2 에는 誤差가 없고

y 만이 誤差를 가졌다고 보아 $x_1 - x_2$ 平面 위의 點(x_1, x_2)에

垂線을 내리면 구하는 平面은 圖 4.2.4와 같이 點 y' 에서 交叉

되는 바 이를 回歸平面 (regression plane)이라 한다. 말하자

면 x_1, x_2 위의 y 의 回歸平面은 $y = a + b_1 x_1 + b_2 x_2$ 로

表示된다. 方程式 $y = a + b_1 x_1 + b_2 x_2$ 의 定數 a, b, c 의

값은 1變數 回歸의 경우와 마찬가지로 變量 y 와 그 回歸線

y' 에 대한 偏差의 自乗合

$$S = \sum \{ y - (a + b_1 x_1 + b_2 x_2) \}^2$$

이 最小가 되도록 정하면 된다.

一般的으로 多元回帰方程式

$$y = a + b_1 x_1 + b_2 x_2 + \dots + b_k x_k$$

의 定数 $a, b_1, b_2, \dots, b_k$ 의 값은

$$S = \sum (y - y')^2$$

$$= \sum \{ y - (a + b_1 x_1 + b_2 x_2 + \dots + b_k x_k) \}^2$$

이 最小가 되도록 하여 얻은 正規方程式에서 計算된다. 正規方程式은 $a, b_1, b_2, \dots, b_k$ 라는 $(k+1)$ 元 1次連立方程式으로 주어진다.

$$\sum y = na + b_1 \sum x_1 + b_2 \sum x_2 + \dots + b_k \sum x_k$$

$$\sum x_1 y = a \sum x_1 + b_1 \sum x_1^2 + b_2 \sum x_1 x_2 + \dots + b_k \sum x_1 x_k$$

$$\sum x_k y = a \sum x_k + b_1 \sum x_1 x_k + b_2 \sum x_2 x_k + \dots + b_k \sum x_k^2$$

다음 表 4.2.8은 獨立變수가 2개일 경우의 回帰方程式의 計算을 表示한 것이다. 이를 보면 x, y 에 第2의 說明變數 x_2 를 추가하여 y 를 x_1 과 x_2 로 說明하려는 回帰分析이다. 回帰方程式은,

$$y = a + b_1 x + b_2 x_2$$

이고 定数計算을 위한 正規方程式은

$$\sum y = na + b_1 \sum x_1 + b_2 \sum x_2$$

$$\sum x_1 y = a \sum x_1 + b_1 \sum x_1^2 + b_2 \sum x_1 x_2$$

$$\sum x_2 y = a \sum x_2 + b_1 \sum x_1 x_2 + b_2 \sum x_2^2 \dots \dots \dots (1)$$

이다. 따라서 表 4.2.8에서 얻은 結果를 (i) 式에 代入하면 다음과 같은 連立方程式이 얻어진다.

表 4.2.8 多元回帰의 計算

y	x ₁	x ₂	x ₁ y	x ₂ y	x ₁ x ₂	x ₁ ²	x ₂ ²	y ²
1	3	2	3	2	6	9	4	1
2	2	1	4	2	2	4	1	4
2	5	1	10	2	5	25	1	4
4	4	3	16	12	12	16	9	16
6	6	5	36	30	30	36	25	36
15	20	12	69	48	55	90	40	61

$$15 = 5a + 20b_1 + 12b_2$$

$$69 = 20a + 90b_1 + 55b_2$$

$$48 = 12a + 55b_1 + 40b_2$$

이를 풀면,

$$a = -0.24 \quad b_1 = 0.27, \quad b_2 = 0.90$$

을 얻는다. 따라서 구하는 回帰方程式은,

$$y' = -0.24 + 0.27x_1 + 0.90x_2$$

가 된다.

이 方程式에서는 $b_1 = 0.27$ 은 x_2 가 不變일 때 x_1 의 증가에

대해서 y 는 平均 0.27 만큼 증가함을 표시하고 또 $b_2 = 0.90$ 은 x_1 이 같고 x_2 가 변할 경우에 x_2 의 증가에 대하여 y 가 0.90 증가함을 表示한다.

多元回帰의 경우에도 推定値에 대한 變量の 標準偏差는 1 變數回帰의 경우와 마찬가지로 다음과 같이 구해진다.

$$S_y = \sqrt{\frac{\sum (y - y')^2}{n}}$$

$$= \sqrt{\sum \{y - (0.24 + 0.27 x_1 + 0.90 x_2)\}^2 / 5} = 0.75$$

表 4.2.9 多元回帰에 대한 標準偏差

y	y'	$y - y'$	$(y - y')^2$
1	2.4	- 1.4	1.96
2	1.2	0.8	0.64
2	2.0	0.0	0.00
4	3.5	0.5	0.25
6	5.9	0.1	0.01
15			2.86

第二編 統計調査方法

第1章．統計調査一般	135
第2章．全数調査と 標本調査	140
第3章．統計調査の 方法	144
第4章．統計調査の 実例	190

法 查 證 提 錄 二 第

132 第 1 章 提 錄 證 查 一 第

14

140 第 2 章 全 體 證 查 提 錄 本 第

141

第 3 章 證 查 提 錄 第 3 章

190

第 4 章 證 查 提 錄 第 4 章

第 1 章. 統計調査一般

1.1 統計調査의 定義와 種類

統計라고 하면 우리는 곧 우리나라의 總人口, 通貨量, 物價指數, 人口, 出生, 死亡, 生産, 輸出, 貯蓄, 失業 등과 같은 社会現象에 関한 것을 생각하게 된다. 이와같이 統計는 어떤 集團에 関한 事實을 説明하는 것이며 따라서 集團이 아닌 個體(例, 金某人, A企業體等)에 関한 個別的인 事實을 説明하는 것은 統計가 아니다. 이와 같이 集團에 関한 事實을 説明하는 것은 統計를 作成하기 위하여 우리는 統計調査를 한다.

統計調査라 함은 合目的的인 表示에 依하여 統計集團 또는 部分集團을 形成함을 말하는 것이나 간단히 말하면 統計資料를 蒐集整理하여 統計를 作成하는 節次이다.

이러한 統計調査의 種類를 살펴보면 다음과 같다.

(1) 全數調査와 標本調査

統計調査는 統計集團에 関한 事實을 알려고 하는 것이므로 統計集團을 形成하고 있는 單位全部를 調査하는 것이 所望스러운 일이나 時間, 費用, 人員 등 많은 制約이 있고 또 正確한 調査라는 觀點에서도 問題되는 點이 있어 오히려 調査單位의 一部만을 調査하는 경우가 더 많다. 이와같이 調査單位를 全部調査하는 것을 全數調査라고 하고 調査單位의 一部만을 調査하는 것을 標本調査라고 한다.

全數調査와 標本調査는 統計調査의 代表的인 것이며 兩調査가 密接한 關係가 있으므로 다음 節에서 詳述하기로 한다.

(2) 第一義 統計調査와 第二義 統計調査

第一義 統計調査는 統計를 作成하는 그 自体를 目的으로 實施하는 調査이며 第二義 統計調査는 統計以外의 目的으로 作成한 記錄書類를 利用하여 統計를 만드는 調査이다. 普通 統計調査의 大部分은 前者의 경우이다.

第二義 統計調査의 例를 들면 人口動態調査, 建築許可 統計, 貿易 統計와 같은 것이 있다.

第二義 統計調査는 報告 또는 記錄의 制度만 있으면 調査의 容易性, 經費, 被調査者의 負擔 등을 考慮할 때 第一義 統計調査를 하는 것 보다 쉽게 統計를 作成할 수 있는 것은 明白한 일이다.

反面 第二義 統計調査에는 다음의 例와 같은 欠點이 많다.

戶籍上으로 申告되는 出生, 死亡, 離婚 등의 統計에 있어서 相當한 期間이 經過한 後 發生事項이 申告되며 이를 다시 具體化 하여 統計를 作成할 때까지는 많은 時間을 消費하여 利用에 不便할뿐만 아니라 申告하지 않는 경우가 많이 있어 精度를 低下시킨다.

(3) 靜態統計調査와 動態統計調査

統計는 靜態統計가 아니면 動態統計에 속한다. 一定한 時點에 있어서의 調査對象의 狀態를 調査함으로써 얻는 統計를 靜態

統計라 하며 一定한 期間內에 繼續 發生하는 事象을 調査함으로써 얻는 統計를 動態統計라고 한다.

5年 또는 10年에 1回씩 實施하는 人口센서스와 分期別調査인 經濟活動 人口調査 또는 每月調査인 人口動態調査, 그리고 鉦工業 센서스와 鉦工業動態調査, 都小売業센서스와 都小売額動態調査 등은 서로 補完하는 調査이며 靜態와 動態를 把握하는 면에서 약간 차이가 있다.

統計를 利用할 때에는 兩者를 관련시켜 利用하면 그 効用을 높일 수 있다.

1.2 統計調査의 必要性

必要한 統計를 既存資料에 依하여 作成할 수만 있다면 資料 蒐集을 위한 時間, 費用, 効力이 節約될 수 있으므로 그위에 좋은 일이 없을 것이다. 그러나 社會現象은 不斷히 變化發展하고 있으므로 항상 必要한 既存資料를 갖고 있기는 어려운 일이다.

그뿐 아니라 既存資料란 그것이 統計를 만들기 爲하여 蒐集된 것이 아니고 다른 목적에 쓰기 爲하여서 蒐集된 것이므로 이를 統計化하는 데는 여러가지 制約이 따르는 것이다. 따라서 基本이 되는 蒐集이 먼저 遂行되지 않으면 안된다.

그런데 統計의 對象이 되는 것은 統計集團이지만 統計調査의 對象이 되는 것은 統計集團 그 自体가 아니고 統計集團을 構成하고

있는 個體 (統計單位)이다.

즉 統計는 集團 그 自体에 關한 數量的 知識을 얻는 것이지만 이 統計의 基本資料를 얻는 統計調査는 現實적으로 個個單位를 對象으로 하여 實施되는 것이다.

이때 統計調査의 現實적인 對象이 되는 個個單位를 調査單位라고 한다.

그러나 統計調査가 비록 個個單位를 對象으로 한다고 하더라도 궁극적으로는 集團에 關한 知識 (統計)을 얻는데 目的이 있는 것이므로 當初 個體 그 自体에 關한 知識을 얻고자 하는 調査

(個別調査)와는 嚴密하게 區別된다. 統計調査가 個別調査와 區別되는 點으로,


첫째, 統計調査는 集團에 關한 知識을 얻기 위한 實踐적인 過程으로서 그 結果는 반드시 統計로 俱現되는 것이며,

둘째, 集團의 構成單位 (調査單位)를 大量으로 觀察하는 것이며,

셋째, 統計化가 可能하도록 調査單位에 對하여 標識을 부여하여야 하는 것이다.

統計調査는 雜多한 社會現象을 統計作成者의 意圖 (目的)에 맞추어 統計集團으로 만들어야 하고 統計調査의 目的을 이룰 수 있도록 각 調査單位에 對한 正確한 심사가 이루어져야 하며 이에 뒤따라 當初의 目的에 맞는 統計表를 作成・發表하여야 한다.

統計調査의 全過程을 圖示하면 다음과 같다.



統計調査方法은 統計作成者는 勿論 統計를 利用하기만 하는 사람도 統計를 올바르게 보고 利用하기 위하여 充分히 理解하여야만 한다.

왜 나하면 統計는 그 目的과 作成者의 立場 및 統計調査方法의 如何에 따라서 얼마든지 다른 結果가 나올 수 있기 때문이다.

統計調査方法은 다음에 調査過程에 따라 詳述하기로 한다.

第2章・全數調査와 標本調査

統計調査는 앞에서 말한바와 같이 統計集團에 關한 事實을 알려고 하는 것이므로 統計集團을 構成하고 있는 單位 全部를 調査하는 것이 가장 所望스러운 것이다. 그러나 實際로 調査單位를 全部 調査한다는 것은 時間, 費用, 人員等 많은 制約이 있다.

뿐만아니라 一部分을 調査하고서도 統計集團에 關하여 正確한 知識을 얻을 수만 있다면 오히려 一部分을 調査하는 것이 所望스러운 것이다.

위에서와 같이 調査單位를 全部 調査하는 것을 全數調査라고 하며 調査 單位의 一部分을 調査하는 것을 標本調査라고 한다.

2.1 全數調査

全數調査는 調査對象이라고 생각되는 모든 部分을 全部 調査하는 것을 말한다. 센서스 같은 것은 그 좋은 例이다. 센서스 뿐만아니라 調査對象의 範圍가 한개의 事務室에 불과한 경우라든가 또는 하나의 洞里라든가 한 學校内の 한 學級인 경우라도 그 調査對象의 最終單位를 全部 調査하는 限 이것은 全數調査인 것이다.

그러나 統計調査의 境遇 全數調査는 一般的으로 그 規模가 크다. 여기서 한가지 注意할 것은 어떤 調査對象의 範圍内に 있는 모든 要素를 調査하는 것만이 全數調査가 아니다. 例를 들면 農場만을 全部 調査하면 全數調査가 되는 것이며 農場以外の 家屋이라든가

学校等 그 地域의 모든 것을 調査하여야 全数調査가 되는 것은 아니다.

2.2 標本調査

標本調査는 部分調査라고도 한다. 즉, 이것은 前述한 諸標本抽出法에 따라 調査對象의 一部分을 選출하여 그 全体를 推定하는 調査를 말한다. 이때 調査對象 全体를 母集團이라고 하며 選출된 部分을 標本이라고 한다. 따라서 여기서 問題가 되는 것은 全体를 代表하는 部分을 如何히 抽出하는가 하는 点이다. 많은 調査가 이와 같은 標本調査法에 依하여 이루어지고 있다.

그러나 原則적으로 時間이라든가 費用, 또는 人員이 허락한다면 全数調査가 좋다는 것은 말할 必要가 없는 것이다. 이것은 勿論 精密性이라는 点에 基準을 둔 말이나 調査目的에 비추어 어느 程度의 誤差는 問題視 안되는 경우라든가 또는 調査目的이 많은 사람들 중에 大多數의 어떤 傾向만을 알고자 할 때에는 구태여 많은 人力과 時間을 浪費할 必要가 없는 것이다. 勿論 어느 程度 精密한 知識이 必要한가에 따라서 決定할 問題이며 이 点에 關하여는 앞의 標本調査論에서 說明하였다.

2.3 全数調査와 標本調査의 比較

全数調査와 標本調査는 어느 것이 더 낫다든가 못하다고

한말로 말할 수가 없다. 兩者는 各各 長短점이 있으므로 調査의 性格에 비추어서 兩者중 하나를 択하여야 한다.

全數調査와 標本調査의 長점을 가려내어 兩者의 選擇基準을 추려 보면 다음과 같다.

(1) 全數調査에는 標本誤差가 없다. 따라서 센서스와 같이 誤差가 전혀 없거나 혹은 그것이 최소한에서 그쳐야 할 경우에는 부득이 全數調査를 할 수 밖에 없다.

(2) 事後의 分類가 細分된 各층마다 이루어져야 하고 正確한 資料가 要求될 때에는 標本調査를 하더라도 많은 標本을 必要로 함으로 이 경우 차라리 全數調査를 하는 것이 좋다.

(3) 母集團(統計集團)이 比較的 작은 경우에는 標本調査를 하더라도 推定の 精度를 높이기 위하여서는 全數調査와 거의 對等한 精度의 많은 標本을 推出하여야 한다. 따라서 이때에도 全數調査를 하는 것이 낫다.

(4) 또 어떤 目的을 위하여서는 標本調査는 많은 制約이 있으므로 이 境遇에는 全數調査를 하여야 한다.

(5) 標本調査를 하기 爲하여서는 標本抽出 推定, 誤差計算等 보다 專問的인 統計知識이 必要하므로 이러한 知識을 가진 사람을 求하기 힘들 때에는 全數調査를 하는 것이 安全하다.

(6) 標本抽出을 위하여는 母集團에 關한 기초자료가 있어야 하는 것인데 이러한 것이 없는 境遇에는 不得已 全數調査를 할 수 밖에 없다.

(7) 全数調査는 調査의 規模가 크기 때문에 巨額의 費用을 必要하게 되는데 이러한 費用의 制約이 있는 경우에는 標本調査를 하면 費用을 節約할 수 있다.

(8) 全数調査는 実査와 集計에 많은 時間이 所要되는데 對하여 標本調査는 이를 短縮 할 수 있으므로 調査 結果를 迅速히 公表하여야 할 경우에는 標本調査를 하는 것이 좋다.

(9) 全数調査에서는 많은 調査人員을 必要로 하며 따라서 未熟한 調査員을 使用하지 않을 수 없음에 對하여 標本調査에서는 尠한 小數의 調査員으로서도 調査가 可能하기 때문에 숙련된 調査員을 使用하지 않으면 안될 경우에도 訓練하기가 容易하다.

(10) 全数調査는 標本誤差가 없는 대신 調査의 大規模性으로 因하여 非標本 誤差가 標本調査에서 보다 크다.

따라서 非標本誤差를 줄이는 것이 重要な 경우에는 標本調査를 하는 것이 좋다.

(11) 그리고 現實적으로 全数調査를 實施할 수 없거나 調査의 性質上 全数調査가 부적당할 경우도 많은데 이러한 경우에는 不得已 標本調査를 하여야 한다. 以上 열거한 것 以外에 標本調査는 標本抽出의 기초자료를 全数調査 結果에 依存하여야 하므로 標本調査를 위하여서도 數年에 一回씩 全数調査를 할 必要가 있고 또 標本調査에서는 推定値 보다 平均이라든가 比率에 더 重點을 주는데 이는 全数調査에서 얻어지는 構造等과 結付됨으로써 더욱 利用價值가 높아지는 것이므로 全数調査와 標本調査는 서로 補完關係에 있다고 할 것이다.

第 3 章 統計調査의 方法

全數調査와 標本調査의 概念과 兩調査의 性格을 앞에서 略述하였다. 그러나 이러한 調査를 實施하고자 할 때에는 調査主体와 客体, 調査事項, 調査時期 其外에 地域 및 方法等 여러가지 制約을 받게 된다. 다음에 調査上 一般的으로 要請되는 몇가지 注意事項을 든다.

(1) 合目的性 : 調査對象이 그 目的과 合理的으로 適合되어야 한다.

예를 들면 貨幣의 一般的 購買力을 調査하려면 都売物価를 調査하여야 하고 勞動者の 生活程度를 觀察하려면 名目賃金 보다 實質賃金の 調査가 더욱 重要하다.

같은 對象의 調査에 關하여서는 目的에 따라 調査의 時期, 場所, 方法等에 差異가 要求될 것은 勿論이다.

(2) 合理性 : 統計對象에 따라서 調査時期・場所 및 그 方法은 科學的인 同時에 經濟的이어야 한다. 이를테면 不必要하게 細密한 數學的 調査는 時間과 努力 및 費用의 經濟上 반드시 合理的인 方途는 아니다.

(3) 資料의 同質性 : 統計資料의 時間的 및 場所的인 比較 利用度を 向上시키기 위하여는 可及的으로 調査項目, 調査時期, 其他 調査方法을 同質性으로 維持함이 必要하다. (例、國際的 各種 統計基準의 定立과 必要性)

(4) 小間多知의 原則 : 標識의 選定에 있어서 簡單한 調査로서 充分히 實質的인 目的을 達할 수 있도록 最善의 方法을 講究함이 必要하다. 이를 少間多知의 原則이라 한다. 이를테면 道德統計에 있어서 國內의 善行을 일일이 調査하는것 보다 犯罪件數를 調査함이 便利하고 國民所得의 調査에 있어서 收入部門을 일일이 調査合計하는것 보다 消費額, 貯蓄額 등이 支出面에서 이를 把握함이 簡便할 수가 있다.

(5) 外圍의 制約 : 觀察對象이 合目的的이라 할지라도 이를 實際 調査함이 事實上 不可能할 경우, 法律 또는 社會慣習上 不容認된 경우 또는 經濟上 不合理한 경우가 있으니 이러한 外圍의 制約은 調査에 있어 미리 留意하여야 한다.

以上에서 列挙한 調査上의 留意點을 念頭에 두고 統計調査를 企劃하여야 함은 勿論이다.

다음에 調査基準 實際調査 調査票의 審査와 集計, 統計表의 作成과 分析等 統計調査의 企劃부터 統計票의 作成까지를 段階的으로 略述한다.

3.1 統計調査의 企劃과 準備

(1) 調査目的

統計調査의 企劃中에서 가장 먼저 하여야 될 일은 調査目的의 設定이다. 調査의 目的이 있으므로 調査가 實施되는 것

이며 모든 調査過程은 調査目的에 의하여 規制되어야 하는 것이다. 그러므로 調査目的의 設定은 매우 重要하다. 그러나 간혹 調査目的이 不明確하고 抽象적이어서 具體적으로 어떠한 것인지 模糊한 것이 있다.

그뿐 아니라 調査過程에 있어서 調査目的이 忘却되어 調査目的과는 엉뚱한 다른 方向으로 調査가 行하여지기도 한다. 이와같이 調査目的에서 離脱되거나 調査目的이 變質되지 않기 위하여는, 첫째 調査目的을 明確하게 그리고 具體적으로 設定하여야 한다. 調査目的에는 一般的으로 무엇에 關한 知識을 必要로 하며 그 知識은 어디에 利用할 것인가를 明白히 하여야 한다.

둘째, 調査目的과 아울러 생각해야 할 것은 調査目的을 實現하기 위하여 統計的 方法이 採択될 수 있는가 하는 統計調査의 適合性 問題이다. 統計調査는 社會現象을 把握하는데 있어 매우 有力한 手段이며 漸次 그 利用度도 높아가고 있지만 모든 分野에서 完全한 手段은 되지 못하고 一定한 限界가 있는 것이다. 統計調査가 그 調査目的을 實現함에 있어 可能하고 適合한 것인가를 判斷하기 爲하여는 다음 事項을 檢討하면 된다.

- (가) 調査의 目的으로 하는 知識이 集團에 關한 知識인가
- (나) 調査對象이 現實적인 集團이거나 集團化 시킬 수 있는 것인가
- (다) 그 集團에 統一된 標識은 賦與할 수 있는가
- (라) 그 調査結果가 數量으로 集團을 正確히 表現할 수 있는 것인가

- (마) 그리고 그 결과가 客觀性和 普遍性이 있는가
- (바) 統計調査가 可能하다 하더라도 現實的으로 隨伴되는 困難
即 大量觀察에 따르는 費用・時間・人員을 克服할 수 있는가
- (사) 大量觀察로 인한 알고 平面的인 知識이 統計目的을 充足
시킬 수 있는가

(1) 調査範圍

調査目的이 決定되면 다음에는 調査範圍를 定하는 것이 重要한 일이다. 調査範圍를 定하는 일은 곧 統計集團의 範圍를 定하는 것이며 바꾸어 말하면 現實의 社會現象을 여러가지 要素에 依하여 統計集團化 시키는 것이다. 따라서 調査範圍는 곧 調査集團인 것이다.

調査範圍는 이를 概念的範圍, 時間的範圍 및 場所的範圍로 나누어 볼 수 있다. 概念的範圍라 함은 알려고 하는 社會現象의 屬性(標識)을 말하는 것으로서 例컨데 鉦工業, 都壳物価等 社會現象의 種類를 限定하고 그 概念을 明確히 規定하여야 하는 것이다.

따라서 鉦工業이라 하더라도 그것이 어떤 規模의 것을 말하는 것인지 明確히 定하여야 하는 것이다. 時間的 範圍는 언제 現在의 社會現象을 調査할 것인가 하는 問題이다. 따라서 靜態統計調査에 있어서는 一定한 時点を 그리고 動態統計調査에서는 一定한 期間을 말하는 것이다.

그리고 場所的範圍라 함은 어느 地域에 對한 社會現象을 調査할

것인가 하는 문제이다. 調査範圍는 調査目的에 依하여서 規定되는 것이지만 人員・費用・時間等 与件에 맞추어서 이를 定하지 않으면 안될 것이다.

(3) 調査單位

統計調査에 있어서 調査의 対象이 되는 것이 調査單位이다. 即 必要한 情報를 提供하여 주는 것이 調査單位이다. 따라서 調査를 実施하기 以前에 調査單位를 무엇으로 할 것인가를 定하여야 한다.

그런데 調査單位는 統計集團을 構成하는 單位와 반드시 一致하는 것이 아님을 注意하여야 한다.

例를 들면 人口센서스에 있어서 人口라는 統計集團의 單位는 한 사람 한사람의 個人이지만 調査는 家口를 調査單位로 하여 實施되는 것이다.

이와 마찬가지로 調査單位는 또한 集計單位・分類適用單位・抽出單位 等과도 다르다. 集計單位는 集計에 있어서의 單位이며 分類適用單位는 各種 分類를 適用시키는데 있어서의 單位로서 모두 統計集團의 構成單位와 一致하는 것이다. 그리고 抽出單位는 標本調査에 있어서의 標本을 抽出하는 單位를 말하는 것으로서 全然 別個의 概念인 것이다.

調査單位를 定하는데 있어서 問題가 되는 것은 첫째로, 무엇을 調査單位로 할 것인가 하는 것과 둘째로, 調査單位를 全部 調査할

것인가 또는 一部分을 調査할 것인가 하는것이 問題이다.

後者は 곧 全數調査와 標本調査의 問題로서 言及되었으므로 여기서는 調査單位의 決定에 關하여 說明하고자 한다.

調査單位는 統計集團의 構成單位와 一致하는 것이 普通이지만, 때에 따라서는 調査單位를 순전히 調査上의 便宜를 爲하여 別途로 定하기도 한다. 調査單位는 가장 正確한 情報를 얻을 수 있고 또한 빠짐없이 情報를 모을 수 있는 最小限의 單位로 하는 것이 普通이지만 鉦工業 調査와 같은 産業調査에 있어서는 一般的으로 事業體를 調査單位로 한다.

(4) 調査項目

調査目的이 確定되면 그 다음에 重要な 것은 調査項目을 決定하는 일이다. 調査項目은 調査目的이 되어 있는 커다란 主題를 여러 次元으로 細分한 것으로 調査標上에 印刷되어 實際로 調査되는 具體적인 事項이다.

調査項目은 調査目的에 關聯되는 必要하고도 充分한 것이 아니면 안되므로 調査項目을 設定하는 데는 細心한 注意와 檢討가 必要하다. 調査項目을 設定할 때에는 누구나 興味가 있고 價值가 있을듯 하다고 생각되는 것은 무엇이나 다 包含시키고 싶은 誘惑을 느끼게 되는데 이는 絶對로 避하지 않으면 안된다. 調査項目은 必要하고도 充分한 最小限의 것이 가장 좋은 것이다.

調査項目 設定에 있어서 檢討하여야 할 點은 첫째로, 그 項目이 實際로 正確한 資料를 얻을 수 있는 것인가 하는 것과 둘째로, 그 項目이 集計할 수 있는 것인가 세째로, 그 項目이 重點의으로

選定되고 調査項目에 寄与하는 것이 明白한가 ね째로, 調査時間, 調査員, 被調査者, 集計費等 現實的인 條件이 具備되어 있는가 等이다.

調査項目에는 그것이 集計되고 分析되는 基本項目과 手段 項目으로서 基本項目을 보다 容易하게 調査할 수 있도록 誘導하는 誘導項目, 調査上の 誤謬를 豫防하고 内容を 照會할 수 있는 对照項目 (Check Item)이 있다.

(5) 調査票

調査票는 調査項目을 一定한 樣式으로 配列한 紙面이다. 調査票는 統計調査에 있어서 매우 重要な 用具로서 그것은 첫째로, 調査할 項目을 明確하게 함으로써 調査項目의 漏落을 防止할 수 있고 둘째로, 各異한 調査員의 觀察을 標準化하고 統一시키며 세째로, 觀察을 強化하고 正確히 할 수 있는 役割을 한다.

調査票作成에 있어서는 調査票体制, 用紙形式 項目의 配列이 重要な 問題이다.

(가) 体制

調査票의 크기는 그것이 包含할 項目數와 調査票의 使用方法에 따라서 左右되겠으나 携帶하기 쉽고 取扱保管에 便利한 크기로 하여야 하며 比較的 간단한 調査票로 調査目的을 達成할 수 있는 경우에는 一般的으로 접을 必要가 없는 정도의 크기가 좋다.

調査票의 紙質은 記入, 分類, 集計, 保管等に 便利한 堅固한 것으로서 카드가 좋을 것이다.

그리고 事前 分類가 可能한 것은 調査票의 色을 달리하여 만드
는 것도 分類 및 集計를 爲하여 便利하다. 調査票의 體制에 있
어서 그 크기와 紙質外에 重要한 것은 첫째로, 實查의 方法을 考
慮하여야 하는 點이다.

實查의 方法에는 面接調査法・配票調査法・集合調査法・郵便調査法・
電話調査法이 있으며 調査票의 記入 方法에는 被調査者가 스스로
記入하는 自計法과 調査者가 記入하는 他計法이 있다. 調査票를
設計할 때에는 위의 어느 方法을 採用한 것인가가 이미 決定되어
있지 않으면 안된다. 그것은 어느 實查方法을 採用할 것인가에
따라서 調査票의 體制가 달라지기 때문이다.

그리고 둘째로, 이와 아울러 생각하여야 할 것은 調査員의 質
도 考慮하여야 한다는 點이다. 能力이 미치지 못하는 調査員에게
複雑한 調査票는 絶대로 避해야 한다. 調査票는 普通 程度의 調
査員도 容易하게 調査할 수 있도록 쉽게 꾸며지는 것이 좋은 것
이다.

세째로, 考慮해야 할 것은 集計의 方法이다. 機械集計에 依하고
자 할때는 機械集計의 專門家와 協議하여 集計에 便利하도록 調査
票를 作成하여야 한다.

(나) 項目配列

調査員은 調査票上의 項目配列 順序에 따라 質問하게 되는
것어므로 質問의 順序가 論理的으로 矛盾이 없어야 하며 応答의

효과를 높이기 위하여 調査項目의 配列에 特別 注意을 쓰지 않으면 안된다. 項目配列은 大體로 다음과 같은 順序에 依하는 것이 좋다.

- 1) 被調査者가 回答하기 쉬운 것부터 始作할 것.
- 2) 可能한 限 論理的인 順序에 依하되 難問題는 中間 또는 끝가까이에 配列할 것.
- 3) 一般的인 項目에서 細部的인 項目으로 展開할 것.
- 4) 可及的 서로 關聯된 項目이나 集計할 때 함께 必要한 項目은 調査票의 같은 部分에 位置하도록 할 것.

以上에 依하여 項目을 配列하면 다음에 各項目에 一連番号 또는 符號를 붙이는 것을 잊어서는 안된다. 그리고 調査票에는 반드시 符號欄을 設置하여야 한다. 符號欄에는 各種 分類를 表示하는 番号 또는 符號를 記入하는 것이다. 符號欄에는 調査票上의 適切한 位置에 設置하되 可能한 限 集計員이 보기 좋은 곳에 모으거나 當該回答의 가까이에 設置하는 것이 좋을 것이다.

(다) 用語形式

調査票上の 用語나 文句는 그 意味가 完全하게 表現되어야 하며 普通의 知識을 가진 사람이면 明確하게 理解할 수 있는 것이 아니면 안된다. 調査要領書가 別途로 있다고 하더라도 可能한 限 調査票만 가지고서도 調査項目의 意味를 正確히 알 수 있도록 하는 것이 좋다.

調査票의 用語形式에 있어서 特別 注意할 것은 調査項目이 主觀

的인 對答을 要求하는 것이어서는 안된다는 것이다. 調査票는 어디까지나 客觀的이며 明確하고 簡單한 答을 얻을 수 있는 形式으로 꾸며져야 하는 것이다.

(6) 分 類

統計調査의 結果 蒐集된 調査票는 調査對象에 關한 가장 詳細한 情報이긴 하지만 이를 一定한 方式에 依하여서 整理하고 集計하지 않으면 集團에 關한 知識을 얻을 수는 없다.

統計에 있어서는 一定한 方式에 依한 整理 即 分類가 絶對적으로 必要한 것이며 이는 반드시 企劃過程에서 그 基準이 設定되지 않으면 안되는 것이다. 分類란 같은 調査對象을 몇개의 구로 나누는 것으로서 同一한 구에 나누어진 것은 同質的인 것으로서 取扱되고 統計數字는 이 구에 關하여서만 나타나게 되는 것이다.

따라서 구內에 있어서의 異質性은 無視되고 個別的인 特殊한 情報는 捨象되어 버리고 마는 것이다. 이와같이 分類란 調査結果의 複雜한 情報의 集計中에서 必要한 것을 가려내어 簡單한 形態로 整理하는 것을 말하는 것이다.

分類에는 質的分類와 量的分類가 있다. 質的分類란 事業(産業)의 種類나 職業의 種類 或은 性別과 같은 質的인 內容에 關한 分類이며, 量的分類란 사람의 年齡, 事業體의 従業員數나 資本金과 같은 量的인 內容에 關한 分類이다.

위의 어느 것이든지 事前에 한개 한개의 구를 어떤 基準에

依하여서 어느 範圍까지로 하느냐 하는 것을 定하지 않으면 안되는 것이다.

各種 分類를 作成하는데 있어서 다음과 같은 것을 考慮하여야 한다.

(가) 調査의 目的에 따라서 分類를 作成할 것.

(나) 分類된 各 組內에 있어서는 모든 單位가 同質的인 것이 되도록 할 것.

(다) 組과 組間은 異質性이 뚜렷이 나타나도록 할 것.

(라) 分類된 單位가 하나도 남김없이 그리고 重複됨이 없이 어떤 組엔가 歸屬되도록 할 것.

(마) 다른 種類의 調査結果와 比較될 수 있도록 分類를 作成할 것. 따라서 標準分類가 있는 것은 되도록 이를 採用할 것.

(바) 量的分類에 있어서는 合理的인 區間을 設定하되 統計의 一般原則에 따를 것.

(사) 質的分類에 있어서 그 內容이 複雜한 것은 十進分類法에 依하여 小分類・中分類・大分類와 같이 分類하는 것이 便利하다.

(아) 分類가 細分되어 組이 過多할 때에는 集團의 內容은 仔細히 볼 수 있으나 全體的 把握에 不便하다. 그反面 分類가 大分되어 組이 過少할 때에는 1個의 組속에 異質的인 것이 無理하게 区分되기 쉽다.

(자) 2個 以上の 組에 重複되어 속하게 되는것. 또는 2個의 組中間에 位置하는 것은 그 所屬을 明白히 規定하여 두어야

한다.

(7) 調査方法

여기서 말하는 調査方法이란 実査(現地調査)의 方法을 말하는 것인데 이는 調査票設計나 調査対象의 決定과 同時에 定하여져야 하는 것이다.

実査의 方法에는 大體로 다음 다섯가지가 있다.

(가) 面接調査法

調査者が 被調査者を 直接 面接하여 質問과 応答를 通하여 調査하는 方法이다. 이 方法에 依하면 被調査者の 応答를 確實히 얻을 수 있고 調査票의 回答率을 높이며 比較的 쉽고 複雑한 調査票도 使用할 수 있을뿐 아니라 正確한 調査를 期할 수 있고 補充的인 情報도 얻을 수 있다는 長点이 있는 反面, 많은 調査員과 費用이 所要되고 調査員에 따라서 応答이 달라지기 쉬우며 調査員의 不正行為가 發生할 念慮가 있는 点 및 特殊한 階層의 사람은 面接할 수 없다는 点 等の 短点이 있다.

(나) 配票調査法

調査者が 被調査자에게 調査票를 配付하고 一定 期間內에 이를 回收하는 方法이다. 이 方法은 面接調査法에 比하여 追及訪問이 덜 必要하고 調査票의 回收率도 比較的 좋으며 費用도 적게 들지만 被調査者 本人이 記入하지 않거나 本人이 記入한다고 하더라도 調査項目을 誤解하여 記入이 不正確하기 쉬우며 또 内容이

造作되거나記入漏落이 생길 可能性이 많은 것이다.

(다) 集合調査法

被調査者를 一定한 場所에 集合시켜 同時的으로 調査票에 記入케 하는 方法이다. 이 方法에 依하면 調査의 說明이나 條件을 被調査者 全員에게 對하여 統一시킬 수 있는 利點이 있으며 被調査者를 容易하게 集合시킬 수만 있다면 費用이 적게 들고 簡便하게 調査를 行할 수 있으며 調査員도 小數로 足할 것이다.

그러나 集合 調査法은 特別한 경우를 除外하고는 使用하기 困難할 뿐 아니라 一般的으로 出席率이 나쁜點과 自計式의 一般的 欠陷은 免할 수 없는 點, 被調査者의 차를 無視하게 되는 點, 出席者의 日當이나 交通費를 支給하게 된다면 오히려 費用이 많이 드는 수도 있다는 點 等の 欠點이 있다.

(라) 郵便調査法

調査票를 被調査者에게 郵送하고 이를 다시 郵便에 依하여 回收하는 方法이다. 이 方法은 費用이 적게 들며 넓은 地域에 調査票를 配布할 수 있으며 面接調査가 어려운 特殊한 階層의 사람에게도 調査할 수 있는 長點이 있다. 反面에 調査票의 回收率이 낮고 回收가 어려움에 따라 督促狀을 여러번 보내야 하므로 回收에 時間을 要한다.

그리고 配票調査에 있어서와 같이 自計式 一般의 欠點이 있으며 調査忌避를 防止하기 위하여서 調査票가 必然的으로 簡單해지는 等の 短點이 있다.

(마) 電話調査法

이는 調査者가 被調査者에게 電話로 質問하여 調査하는 것이다. 이 方法에 依하면 簡單하고 迅速하게 調査할 수 있으며 費用도 적게 들수 있다. 그러나 電話를 가진 사람만을 対象으로 하여야 하는點, 調査時間이 짧아야 되므로 簡單한 調査以外에는 할 수 없다는 點이 決定的인 短點이다.

위의 여러 方法中에서 集合調査法 等은 制限된 特殊한 調査에만 사용되는 方法이며 一般的으로는 面接調査法・配票調査法・郵便調査法의 順으로 많이 사용되는데 特히 面接調査法은 回收率이 높고 正確하고 詳細한 調査를 期할 수 있다는 長點으로 因하여 가장 널리 사용되고 있다.

따라서 위의 方法 以外에 調査票 記入方法으로서 自計式과 他計式이 있는데 自計式이란 被調査者가 스스로 記入하는 것이고 他計式은 調査員이 記入하는 것이다.

따라서 面接調査法과 電話調査法은 他計式에 依하는 것이며 配票調査法・集合調査法・郵便調査法은 自計式에 依하는 것이다. 이中 他計式은 費用의 問題와 調査員 偏嗜의 問題가 있긴 하여도 自計式에 比하여 훨씬 優越한 것으로 생각되고 있다.

(8) 調査員

調査員은 廣義에 있어서는 調査管理者 現地調査員 및 集計員을 含包한 모든 調査從業者를 意味하나 狹義로는 現地 調査員만을

가르친다.

여기서는 現地 調査員中에서도 特別 面接調査法이 採用되는 경우의 調査員(面接調査員)을 中心으로 하여 說明하고자 한다.

社會現象을 다루는 모든 調査에 있어서는 被調査者가 얼마나 眞實한 情報를 提供하여 주는가 하는 被調査者의 協力的 態度와 調査員의 正確하고 熱誠적인 觀察態度가 가장 重要하다 할 것이다.

被調査者는 各己 性別, 年齡, 學歷, 階層, 思想, 性格 등이 다른 各樣의 屬性과 個性을 가지고 있어서 그들에게서 한결같은 協力を

얻고 그들은 正確히 觀察한다는 것은 容易한 일이 아니다. 調査員은 이와같은 어려운 일을 担当하는 것이며 調査員의 能力과 努力如何에 따라서 그 調査의 成功与否가 左右된다고 하여도 過言이 아니다.

따라서 優殊한 調査員을 確保하고 充分히 訓練시키는 일이 調査를 成功케 하는 하나의 關鍵이라고 할 수 있는 것이다.

(가) 調査員의 資質과 性格

調査員의 適合한 性格으로서는 責任感, 誠實, 明朗, 順応性, 探究心, 忍耐力, 公正性 등이 要求되며 正確한 理解力과 判斷力 그리고 調査에 對한 興味 등이 要望된다. 그 外의 條件으로서는 健康하고 普通水準 以上の 教養과 知識이 必要하며 調査에 專念할 수 있는 時間的 여유가 있을 것이 要求된다.

調査員의 年齡은 20~30 歲가 適合하며 性別은 一般的으로 男性이 適合하나 경우에 따라서는 女性이 適合할 때도 있다. (例 家

計調査) 또 經驗이 없는 調査員 보다는 經驗이 있는 調査員이 一般的으로 낫다고 할 수 있겠으나 正規의 訓練을 받지 않고 막연 하게 調査員으로서의 經驗만을 가지고 있는 것은 반드시 낫다고 할 수 없으며 오히려 調査에 無誠意하고 內容을 造作할 可能性이 있다.

(나) 調査員의 偏嗜

調査員은 그의 性格과 資質에 따라서 一定한 偏嗜를 갖기 쉬운데 이는 調査員의 偏見, 先入觀, 思想, 性格 등에 基因하는 것으로 同一한 対象의 回答을 듣고도 各異한 두 사람의 調査員에 있어서는 各異한 結果가 나타나는 것이다. 調査員에게는 自己의 立場이나 主觀 信念에 따라서 事物을 理解하려는 傾向이 있기 때문이다.

調査員의 이러한 偏奇는 調査結果에 커다란 誤差를 가져오기 쉬우므로 調査員을 採用할 때나 調査員을 指導 訓練할 때 特히 이를 避하고 除去하도록 努力하여야 한다.

(다) 調査員의 訓練

調査員의 適合한 資質은 반드시 生来的인 것은 아니며 各種의 訓練에 依하여서 研磨되고 完成될 수 있는 것이다. 勿論, 生来的인 素質도 重要的 것이므로 좋은 調査員을 얻기 爲하여서는 知能, 性格 등에 對한 「테스트」에 依하여서 미리 選拔하여야 하겠으나 實際問題로서 調査員 採用은 그다지 慎重히 다루어지지 않고 있으므로 特히 調査員의 指導와 訓練을 철저하게 하지 않으면 안

되는 것이다.

調査員の 訓練의 目的은 調査員에게 適合한 資質을 키워주고 調査에 關한 直接的인 知識을 부여하여 面接技術을 研磨시키는데 있는 것이다.

따라서 實際로 調査員 訓練을 爲한 講習을 實査直前の 調査準備 過程에서 實施하게 되는데 이때에 調査員에게 調査의 目的과 意義를 充分히 認識시키고 아울러 具體적으로 調査項目의 定義, 記入方法, 其他 實査中에 일어날 것으로 豫想되는 여러가지 事項에 關한 處理方法等を 詳細히 指示하여야 한다.

그리고 이러한 具體적인 指示는 반드시 調査要領書나 調査指示書로서 作成되어 調査員에게 交付되어야 한다.

調査員の 訓練方法으로는 實地로 練習調査를 實施하여 그 結果를 1枚씩 慎重하게 檢討하여 調査員이 誤解하고 있는 點, 調査票記入方法의 不充分한 點을 指摘하고 注意를 환기하는 方法이 많이 使用되고 있다.

그런데 調査員에 對한 調査要領의 指示는 調査員을 한 場所에 集合시켜 一時에 하는 것이 좋다. 그것은 調査指示者와 時間 및 場所에 따라 指示內容이 달라질 念慮가 있으며 그로 因하여 調査員의 統一된 知識과 觀點을 期할 수 없게 되기 때문이다.

(9) 調査區

調査의 範圍가 狹小한 1個地域에 局限되어 있거나 標本調査

인 경우에는 特別히 調査區를 設定할 必要가 없으나 「센서스」와 같이 全國 또는 道와 같은 廣大한 地域을 調査의 範圍로 하는 경우에는 한 사람의 調査員로서는 全地域을 担当할 수 없고 여러 사람의 調査員이 地域을 分擔하여야 하므로 이를 爲한 調査員의 分擔地域을 設定할 必要가 있다.

이와같은 各 調査員의 分擔區域을 調査區라고 한다. 調査區를 設定하는 目的은 調査地域內에 있는 調査對象을 하나도 漏落하지 않고 또한 重複됨이 없이 捕捉하려는 데 있다. 따라서 調査區를 設定할 때에는 漏落된 地域이 없는가 調査區와 調査區間의 境界가 明確한 가를 特別히 念頭에 두어야 한다.

한 調査區에는 한 調査員을 配置하는 것이 原則이므로 調査區의 數는 動員 可能한 調査員의 數에 依하여 定하는 것이 普通이다.

그리고 調査區의 設定方法으로는 行政區域에 依하여 市, 郡 單位 또는 里, 洞單位로 하는 方法과 地勢 및 交通에 따라서 決定하는 方法이 있다. 調査區를 設定할 때는 위의 方法中 어느 方法을 採할 것인가를 決定하고 特別히 全國的인 「센서스」에서와 같이 많은 調査區를 設定하여야 할 때에는 可及的 크게 擴大된 地圖를 準備하여 이에 依하여 區域을 明確히 劃定하는 것이 좋다.

그리고 調査區가 많은 때에는 數個의 調査區를 指導 및 管理할 指導區를 設定하는 것이 調査管理上 效果가 있다.

(10) 調査時期

調査の企劃이 完了되고 이에 따른 準備가 갖추어지면 調査를 実施하게 되는 것이므로 調査時期를 特別히 考慮할 必要가 없을 듯 하나 事實은 調査의 時期가 企劃過程에서 먼저 定하여지고 이에 맞추어 企劃 및 準備日程이 짜여 지는 것이 原則이다. 그것은 調査時期가 調査의 進行과 結果에 적지 않은 影響을 주는 때문이다. 만일 調査의 時期가 調査의 時間的 基準과 너무 떨어진 1年 또는 數年前의 事實을 調査한다면 그 調査結果는 內容이 不正確할 뿐 아니라 結果의 利用価値도 낮아지게 될 것이며 또 調査 時期가 調査対象을 찾아가기 어려운 季節이라면 그 調査는 中途에서 一段 保留를 하지 않을 수 없게 될 것이다.

따라서 調査時期는 調査가 可能하고 容易하며 되도록 調査基準時点으로부터 너무 오랜 時日이 지나지 않은 때를 挾하도록 하여야 한다.

具體적으로 말하면 調査가 可能하고 容易하기 위하여서는 먼저 그 以前에 企劃의 準備가 되어 있는가 등을 考慮하여야 한다는 것이다.

調査時期는 調査基準時点에서 너무 멀리 挾하는 것도 좋지 않지만 調査基準時点에서 너무 近接시켜도 좋지 않은 경우가 있는 것이다.

例를 들면 企業체의 生産 또는 財務活動調査에 있어서는 적어도 企業체가 帳簿整理를 끝내거나 決算을 完了한 後를 調査時期로 挾

하여야 할 것이다. 그리고 調査를 年1回 実施하는 경우에는 季節的인 條件을 勘案하여 暴暑酷寒을 避하여야 하며 또 被調査者가 大部分 바쁜때는 扞하지 않는 것이 좋다.

実査期間은 위의 調査時期에 一定한 期間을 設定한 것인데 그 期間의 長短은 調査対象數와 調査内容 및 調査員數에 依하여서 決定된다.

実査期間은 짧을수록 좋을 것이므로 費用의 問題가 있겠으나 可能하다면 有能한 調査員을 많이 動員시켜 可及的 実査期間을 短縮시키도록 하는 것이다.

(11) 実査管理, 集計等 計劃

統計調査의 企劃은 調査準備로 부터 結果公表의 最終 段階까지의 全過程에 걸친 事項을 全部 網羅하여 이루어져야 하므로 実査段階 以後에 이루어질 実査管理, 調査票審査, 集計等에 關하여서도 企劃過程에서 미리 計劃되지 않으면 안된다.

実査管理에 關하여서는 正確하고 迅速한 実査의 運營方法을 細密한 部分까지 計劃하여야 하며 調査票審査에 關하여서는 調査票의 内容檢討 및 分類를 效果的으로 할 수 있는 方法을 講究하여야 한다.

그리고 集計에 있어서는 集計方法, 集計場所, 集計員, 集計表樣式, 公表樣式 等に 關하여서 具體的인 計劃이 이루어져야 한다. 特히 集計計劃은 調査項目의 設定과 調査票設計時에 있어 同時에 考慮되

어야 한다. 그럼으로써 集計가 不可能한 것이나 利用上에 意味가 없는 項目은 除外될 수 있는 것이다.

以上の 実査管理, 調査票審査 및 集計에 關한 具體的 事項은 後述하고자 한다.

(12) 被調査者の 協助

実査는 被調査者を 相對로 하는 것이며 被調査者が 積極的으로 調査에 協助하지 않고서는 調査의 目的을 達成할 수 없는 것이므로 事전에 被調査者の 協助를 얻는 方案을 講究하여 두는 것이 主要한 일이다.

実査는 그것이 어떤 種類의 것이든 他人의 時間과 情報를 侵害하는 것이므로 被調査者の 協助를 얻기 爲하여서는 무엇보다 먼저 이와같은 侵害를 正当化시키고 相對方에 認識시키는 것이 緊要하다.

이를 위하여서는 이 調査가 被調査자와 社會를 爲하여 實施되며 有益한 結果를 가져올 것이라는 點. 그리고 調査實施機關이 權限있는 機關이거나 公的機關인 點 等を 強調하여야 할 것이다.

또한 被調査자가 調査에 非協助的인 理由의 하나가 秘密漏洩에 對한 憂慮에 있으므로 이러한 憂慮를 払拭시키도록 努力하는 것도 重要하다.

따라서 調査員이 実査에 着手하기 前に 被調査자에게 調査의 目的과 趣旨, 調査協助에 關한 간곡한 부탁, 調査內容은 절대로 秘密로 한다는 內容의 調査協助依頼文을 보내는 것이 좋다. 그리고

豫算이 許容하면 이러한 個別的인 協助依賴文外에 新聞, 放送, 포스타等を 通하여 調査의 重要性을 널리 周知시키는 것도 좋다. 이밖에 調査實施機關이 權限이 없거나 公的機關이 아닌 때에는 다른 有力機關의 支援을 받는 것이 매우 效果가 있다.

被調査者の 協助를 얻는 方法으로서 謝礼品을 주는것도 좋은 方法이다.

謝礼品을 주기 위하여서는 莫大한 費用이 所要되지만 被調査者の 協助와 수고에 報答하는 뜻에서 実査後에 謝礼品을 贈呈하는 것이 效果的이다. 또한 実査를 担当한 調査員에게는 調査員의 身分을 証明하고 調査機關을 明示한 調査員 身分証을 發給하여 実査時에 被調査者에 提示케 할 뿐아니라 服裝이나 言語를 단정하게 하여 좋은 印象을 주도록 하는 것도 被調査者の 協助를 얻는데 크게 도움이 될 것이다.

(13) 豫備調査

実査에 들어가기 前에 企劃된 内容들이 現實적으로 妥當한가 하는 것을 確認하기 爲하여 豫備調査(準備調査 또는 試驗調査라고도 한다)를 하는 것이 普通이다.

먼저 試驗調査에서는 主로 調査單位, 分類方法, 調査票樣式, 調査項目의 定義, 調査項目의 排列, 調査方法, 調査員의 業務量, 被調査者の 協力程度 등과 같이 調査企劃上에 나타난 諸般 事項에 關하여 그 妥當性을 檢討 確認하는데 必要하지만 準備調査는 「센서스」와 같이 大規模의 調査에서 豫備名簿나 標本名簿(Sample

List)를作成하기 위한 実査에 前提的인 作業인 것이다.

따라서 企劃上의 欠陥을 試驗하기 위하여 實施하는 豫備調査를 試驗調査라 하며 이는 企劃의 完了後에 하는 것이 아니라 企劃途中 即 実査의 前期作業으로 實施되는 것이 通例이다.

3.2 實際調査(現地調査)

(1) 実査의 重要性

統計調査의 企劃과 準備가 끝나면 実査의 段階로 들어가게 되는데 이 段階에서는 調査員이 被調査者로부터 情報을 얻고 이를 調査票에 記入하며 調査管理者는 実査를 管理하고 記入이 完了된 調査票를 蒐集하게 된다.

実査의 方法에는 面接調査法, 配票調査法, 集合調査法, 郵便調査法, 電話調査法 등이 있음은 既述한 바 있으나 여기서는 面接調査의 경우를 中心으로 하여 說明하기로 한다.

統計調査가 物理現象을 다루는 경우에 있어서는 대개의 경우 調査對象이 下等動物이건 無生物이건 간에 對象과 論議하는 일이란 있을 수 없는 것이다. 그러나 統計調査가 社会現象을 다루는 경우에는 調査對象인 個人 또는 社会集團이 積極적으로 이에 参与하지 않고서는 不可能한 때가 많다. 다시 말하면 社会現象에 關한 調査가 成功하느냐 失敗하느냐의 重要한 關鍵은 被調査者가 얼마나 積極적으로 協力하여 眞實한 情報을 提供하여 주느냐에 달

려 있다.

그런데 被調査者는 各已 다른 性格과 特徵을 가지고 있으므로 이러한 被調査者로부터 한결같이 積極的인 協助를 얻고 正確한 調査를 期한다는 것은 결코 容易한 일이 아니다. 社會現象을 다루는 統計調査에 있어서 實査 技術的인 方法이 크게 重要視되는 것은 이 때문이다.

아무리 統計調査의 企圖이 잘 되었다 하더라도 實査過程에서 無能하고 無誠意한 調査員의 熟練되지 못한 調査는 內容이 不正確한 結果를 가져올뿐만 아니라 被調査者의 非協助的인 態度만 助長시킴으로써 將來의 調査마저도 困難하게 만들 우려가 있는 것이다.

대체로 被調査者는 調査를 忌避하거나 眞實한 對答을 거부하려는 傾向이 있다.

이것은 자기의 事實上의 秘密이 外部에 漏洩됨으로써 同業者間의 競争에 不利하여 지거나 納稅額에 影響을 주지 않을까 하는 疑懼心과 調査에 應하려면 바쁜때의 貴重한 時間이 浪費된다고 생각하기 때문이다. 그러나 우리가 調査目的을 達成하기 위하여는 이러한 被調査者를 우리가 意圖하는 대로 이끌고 가서 直實한 對答을 하도록 만들지 않으면 안되는 것이다.

그러므로 이를 위하여서는 무엇보다도 調査員이 훌륭한 資質과 態度 그리고 充分한 知識을 구비하고 誠意있게 調査에 임하여야 하며 또한 그때그때의 狀況에 適應하여 適切한 技術的인 面接方法

을 항상 研究하지 않으면 안되는 것이다.

(2) 実査의 管理

調査員에 依한 実査는 調査가 企圖된대로 円滑히 遂行되도록 엄격히 管理되지 않으면 안된다.

먼저 調査員이 実査에 着手하기 前に 調査管理者는 調査員으로부터 実査計劃書 또는 実査日程表를 作成하도록 하여 이를 檢討하고 調節하여야 한다. 그리고 이 実査計劃書에 의거 調査員의 実査를 管理・監督하는 것이다.

調査員이 実査를 進行하고 있는 동안에는 調査員이 調査対象을 틀림없이 訪問하여 正確한 調査를 하도록 이를 통제하여야 한다.

調査員中에는 被調査者를 만나지도 않고 卓上에서 調査票를 造作記入하는 者도 있으며 被調査者를 訪問하지도 않고 또는 但1回 訪問하고서는 被調査者の 不在 혹은 調査不能이라고 報告하는 事例가 있으므로 調査管理者는 이러한 일이 發生하는 것을 최대한 防止하여야 하는 것이다. 調査員의 이러한 行爲를 統制하는 方法으로는 調査管理者가 不時에 任意의 調査対象을 訪問하거나 調査対象에게 郵便 또는 電話로 調査員의 訪問与否와 態度를 照会하는 等の 方法이 있으며 이 外에 調査票上에 对照項目을 設置하여 調査員을 統制하는 方法도 있다. 卓上造作은 않더라도 他人에게 調査를 依頼하거나 電話 또는 郵便으로 調査하는 것도 이를 防止하여야 한다. 実査도중 調査不能이 나오는 경우에는 調査管理者는

그 事由를 檢討하고 再調査를 指示하거나 標本調査인 경우에는
調査対象인 標本을 代替하여야 하는데 이때 注意할 것은 標本の
代替는 調査員이 任意로 하여서는 결코 안되며 調査管理者에 依하
여 엄격히 다루어져야 한다는 것이다.

그리고 이와 別途로 調査管理者는 調査不能의 原因을 면밀히 分
析하여야 한다. 調査不能에는 여러가지 原因이 있겠으나 대체로
調査対象이 所在不明일 경우, 調査対象이 不適格한 경우, 被調査者가
不在인 경우, 被調査者가 調査에 不応하는 경우 등이 調査不能한
例이다. 調査対象의 所在가 不明한 것은 当初 名簿가 잘못 作成
되었거나 名簿가 作成된 後에 調査対象에 變動이 생긴 때문인데
이러한 경우에는 가능한 限 名簿를 修正하고 調査하여야 한다.

그리고 調査対象이 不適格한 경우, 예컨대 調査対象이 調査範圍
밖에 있는 때와 같은 경우에는 대체로 実査를 할 必要는 없겠
으나 調査管理者는 반드시 그 事實与否를 確認하여야 한다.

被調査者가 出他하여 不在인 경우에는 결코 調査不能으로 處理하
여서는 안된다. 이 때에는 반드시 재차 訪問하여 調査를 遂行
하여야 한다.

그런데 가장 困難한 것은 被調査者가 調査에 応하기를 거부하는
경우이다. 그러나 이 경우에도 調査員은 一次 거절 당하였다
하여 調査를 포기하여서는 안되며 재차 誠意있는 努力을 하여야
한다. 그래도 調査를 不応하는 경우에는 調査管理者가 直接 被
調査者를 訪問하여 実査를 하여야 한다. 이 외에 調査管理者는

調査員이 実査途中에 実査에 関한 疑問점을 問議하여 왔을때 이에 对答하여 주어야 하며, 調査員의 実査上の 各種 隘路点を 해석하여 야 한다. 뿐만 아니라 調査員이 불의의 사고로 調査를 遂行할 수 없게 되는 경우에는 期間内に 実査를 完了할 수 있도록 各 별한 对策을 講究하여야 한다.

調査員은 実査가 끝나 調査票를 実査管理者에게 提出케 되는데 이에 앞서 調査員으로 하여금 스스로 調査票를 철저히 檢討하고 完全히 整理하여 提出케 하여야 한다. 꼭 調査員으로 하여금 매일 調査가 끝났을때 그날의 調査된 調査票에 对하여서는 記入 漏落, 記入의 不完全, 記入上の 錯誤를 스스로 発見하여 是正케 하며 또한 글자를 알기 쉽게 하고 記入法의 統一을 기하여 計算한 것이 있으면 이를 檢算하고 경우에 따라서는 計算値의 記入을 行하게 하는 등 調査票를 整理하도록 한다. 그리고 調査員이 割当된 調査対象에 对하여서 調査를 全部 끝냈을 때는 지정된 対象에 对하여 빠짐없이 그리고 錯誤없이 調査가 完了되었는가를 스스로 確認케 한 후에 調査票를 提出하게 하여야 한다.

調査員이 記入完了한 調査票를 提出하였을 때는 되도록 現地에서 調査員을 面前에 두고 調査票를 檢査하여야 한다. 여기서 調査票上の 記入漏落, 記入不完全, 記入의 錯誤, 調査員의 造作 등을 発見하여 이를 修正케 하거나 再調査를 指示하여야 한다. 이어서 調査員이 割当된 実査를 모두 終了하였을 때에는 所定期日에 一定한 場所에 調査票를 蒐集하고 여기서 調査対象別로 調査票를 点

檢하여 調査漏落이나 重複調査 및 調査對象의 同一性 여부 등을 確認하여야 하는 것이다.

(3) 被調査者와의 面接方法

(가) 面接의 準備

調査員은 被調査者와의 面接을 實施하기전에 먼저 面接調査를 가장 效果的으로 할 수 있도록 計劃을 세워야 한다. 即 어떻게 하면 時間과 距離를 短縮하여 被調査者를 訪問할 수 있는가를 研究하여 路程, 日程表를 짜야 하며 調査에 앞서 調査要領書나 調査指示書를 熟讀하고 調査票, 調査要領書, 記入道具, 地圖等 持參할 物件을 点檢하여야 한다.

다음 누구를 面接對象으로 할 것인가를 定하여야 한다.

面接對象으로 가장 適合한 사람은 말할 것도 없이 調査內容에 가장 精通하고 同時に 調査員에게 自由로 말할 수 있는 位置에 있는 사람이어야 한다.

事業體 內容을 調査하기 위하여서는 그 事業體의 幹部를 面接하지 않으면 안될 것이다.

面接對象이 定하여지면 調査員은 可能하면 그를 訪問하기 前에 그에 關한 知識, 즉 그 사람의 性格, 過去, 및 그가 속하여 있는 部分 社會에 있어서의 慣行 等 豫備知識을 얻도록 하여야 한다.

이와같은 豫備知識은 面接을 円滑하게 이끌고 被調査者의 積極的인 協助를 얻는데 큰 도움이 된다.

다음 調査員은 被調査者에게서 調査할 問題에 關하여 大略的인

知識을 갖추어야 한다.

그리고 狀況이나 條件에 따라 面接進行의 大綱을 事전에 計劃하여 두는것도 面接의 時間을 節約하고 序頭를 効果있게 만들며 要点을 강조할 수 있다는 点에서 반드시 잊어서는 안될 것이다.

끝으로 面接에 앞서 面接場所와 面接時間을 定하는 것도 重要하다.

面接場所와 時間은 調査員의 便宜안에 依하여서 定할 것이 아니라 被調査者가 가장 安樂하게 이야기 할 수 있는 條件을 考慮하여 定하여야 한다.

一般的으로 事業体の 內容을 調査하는 것이 라면 面接場所로서는 그 事業体の 事務室이 가장 適當하다.

그것은 必要한 帳簿와 記錄을 即時 參考할 수 있기 때문이다. 그리고 面接時間은 被調査者가 그다지 나쁘지 않고 별다른 일이 없으면 疲労를 느끼지 않을 때를 忖하는 것이 좋다.

可能하면 事전에 場所와 時間을 被調査者와 約束하는 것이 좋을 것이다.

(나) 面接의 場所

面接은 대개 다음과 같은 順序에 따라 進行되어진다.

第1段階：最初로 被調査者와 接觸하는 段階로서 먼저 所持한 証明(身分証)이나 명함을 提示하고 人事를 교환하며 自己의 所屬된 調査機關을 밝힌다.

그리고 분위기를 造成하여 가면서 面接의 趣旨와 目的을 相對가

納得할 수 있도록 說明한다. 이때에 所持한 調査協助依頼文이 있으면 이를 주도록 한다.

第2段階: 여기서는 두사람의 呼吸을 調整하고 親密하고 부드러운 분위기를 만들어 相對方이 親密感을 갖고 積極적으로 協助하도록 努力한다.

第3段階: 最初の 接觸이 끝나고 또 調査員과 被調査者에 親密한 분위기가 造成되면 被調査者を 主役으로 하여 一般的이고 全体的인 이야기를 교환하게 된다.

이 段階에 있어서 이야기 하는 사람은 주로 被調査者이며 調査員은 주로 相對方의 이야기를 關心깊게 들어야 한다.

예를 들면 相對方으로 하여금 一般的인 景氣라든가 業界의 動向을 이야기 시키는 것이다.

第4段階: 이 段階에 있어서는 調査員이 主役이 되어 本格的인 質問을 한다.

調査員은 대체로 주어진 調査票의 順序에 따라 한 項目 한 項目씩 質問하고 그 對答을 調査票에 記入하는 것이다.

第5段階: 이 段階에서는 相對方이 特히 하고싶은 이야기나 意見を 듣고 이를 参考하여 調査를 補完한다.

그리고 被調査者가 前段階에서 錯誤한 것을 깨닫고 스스로 訂正하여주는 境遇에는 이를 確認하여 調査票의 記入을 訂正한다.

第6段階: 이 段階에서는 調査가 完全히 이루어졌는가를 確認한다.

即, 調査員이 調査票上에 記入漏落이나 記入不完全, 記入錯誤가 없는가 調査票를 檢討하는 것이다.

그리하여 万若 調査票上의 不備를 発見하면 即席에서 이를 補完하여야 한다.

이 段階에서의 調査票檢討는 매우 重要な 일인데도 一般的으로 疎忽히 생각되기 쉬운데 여기서 이를 疎忽히 하면 後에 이를 補完하기란 極히 힘든 일이므로 特히 注意를 要한다.

第7段階: 面接이 끝났으므로 感謝의 뜻을 表示하고 面接場所를 물러난다.

感謝는 眞心으로 表示하여야 하며 設혹 目的을 達成하지 못한 境遇라도 他人의 時間을 多少나마 消費하게 하였으므로 반드시 感謝의 뜻을 表示하여야 한다. 그리고 이때 今後の 繼續調査를 確保할 수 있는 素地를 만들도록 親密하고 좋은 印象을 남기도록 하여야 한다.

以上으로 面接의 順序를 段階적으로 区分하여 說明하였으나 이 順序는 유연성이 있는 것이므로 경우에 따라 相當히 變形되지 않으면 안되는 것이다.

그리고 週期的으로 調査되는 繼續調査에 있어서는 第1段階와 第2段階는 省略되는 것이 普通이다.

(다) 面接上の 注意

1) 端正하고 素朴한 외모를 갖추어 被調査者에게 좋은 印象을 줄것.

2) 부드러운 態度와 말씨로 自然스럽고 率直하게 이야기 할 수 있는 溫和한 분위기를 만들어 겸손과 禮節을 잃지 않도록 할 것.

3) 自由롭게 이야기 하면서도 眞摯性和 沈着性을 나타내어 相對方이 輕蔑感을 갖지 않도록 하며 相對方의 信賴를 얻도록 할 것.

4) 相對方에게 本心에서 우러나오는 따뜻한 理解와 同情을 가지고 接한다.

5) 相對方의 氣分, 言外의 말, 익숙지 못한 表現에서 相對方 眞意를 把握할 수 있도록 細心한 洞察力을 發揮할 것.

6) 相對方과 論爭하거나 相對方을 輕蔑하는 빛을 보이지 말것.

7) 自己의 態度, 質問, 判斷이 正當한가를 反省하고 檢討할것. 自己의 判斷에 너무 確信을 갖는 것은 훌륭한 調査員이 아니다.

8) 忍耐와 責任感을 가질것. 指定된 被調査者를 찾아서 만나지 못한 때에는 몇번이라도 다시 찾아가야 하며, 때로는 相對方에 依하여 參을 수 없는 일을 當하더라도 忍耐할 것. 그리고 眞實하지 못한 일이라고 생각되는 것은 安이하게 處理하지 말고 끝까지 眞實을 찾아낼 것. 이것은 任務에 忠實한 責任感에서 생기는 것이다.

9) 끊임없는 關心과 研究로서 充分한 知識을 研磨할 것.

10) 相對方과 面接하지도 않고 調査員이 멋대로 調査票를 造作記入하는 일이 결코 없도록 할것.

3.3 調査票의 審査와 集計

(1) 調査票의 審査

調査票의 審査는 実査에 依하여 蒐集된 調査票의 内容을 審査하여 錯誤나 記入漏落을 発見하고 이를 訂正하여 集計할 수 있도록 調査票의 記入内容을 完全하게 하는 作業이다.

調査票審査作業의 内容을 살펴보면 다음과 같다.

(가) 指定된 調査対象에 關하여 調査票가 確保되었는가를 点檢하는 것.

(나) 調査票中에 記入漏落된 項目이 없는가 檢討하는 것.

(다) 記入이 不完全한 項目을 檢出하는 것.

(라) 判讀하기 어려운 文字와 數字를 고쳐 쓰는 것.

(마) 調査票記入法을 統一하는것.

(바) 計算錯誤를 発見하여 訂正하는 것.

(사) 調査票記入錯誤를 発見하는 것.

(아) 調査員의 不正記入을 発見하는 것.

(자) 計算値를 記入하는 것.

以上の 것中(사)의 調査票의 記入錯誤는 調査員 또는 被調査者가 不注意에 起因하는 内容上の 錯誤이므로 이를 調査票審査 過程

에서 發見하기는 어려운 것이다. 이는 調査票의 構成이나 調査員의 選擧 또는 指導에서 充分히 注意하여 미리 豫防토록 하여야 하나 調査票 審査過程에 있어서도 이러한 錯誤를 發見하도록 最大의 努力을 기울이지 않으면 안되는 것이다. 이를 爲하여서는 다음과 같은 方法을 使用할 수가 있다.

첫째로 個個의 調査票中에서 關聯되는 다른 項目과 對照하여 그間에 矛盾이 發見되면 錯誤가 存在하는 可能性이 있다.

둘째로 調査員마다 簡單한 集計를 하여 다른 調査員의 그것과 比較하여 현저한 差異가 있을 경우에는 어느 調査員인가 不注意를 犯했을지도 모른다.

세째는 全体에 對하여서 簡單한 集計를 하여 豫想과 동떨어진 結果가 나올 경우에는 일단 그 項目의 內容을 의심할 수 있을 것이다. 調査票審査에는 実査管理者에 依한 現地審査와 別途 調査者에 依한 事後審査의 段階가 있으며 後者は 다시 調査規模에 따라 地方審査와 中央審査의 段階로 나누어 진다.

다만 郵便調査法을 使用할 때에는 審査者에 依한 審査만이 1 段階 行하여질 뿐이다.

実査管理者에 依한 審査는 대개 審査期間中 調査員이 記入 完了한 調査票를 提出하였을 때 調査員의 面前에서 한다. 여기서는 記入漏落, 記入不完全, 記入의 錯誤, 調査員의 不正等の 發見에 注力하고 發見된 境遇에는 再調査를 命한다. 同時에 보기 힘든 글자 記入法の 不統一에 注意한다. 現地審査는 実査期間中 毎日하는 것

이 좋으며 적어도 몇 번은 하여야 한다. 그리고 調査員이 割當된 実査를 모두 끝마쳤을 때는 調査漏落이나 重複없이 割當對象의 調査가 完了되었는가를 確認하여야 한다.

実査가 모두 完了되고 調査票가 一定한 場所에 蒐集되어 審査員에 依하여서 一齊히 実施되는 調査票 審査에 있어서는 簡単な 集計에 依하여서 記入上の 錯誤나 調査員의 不正을 発見하여 訂正 或은 調査票의 破棄를 하고 또 計算을 檢算하며 計算値를 記入하고 境遇에 따라서는 公백 난에 回答을 統計的으로 推定하여 메꾸기도 한다.

以上과 같이 調査票 審査는 実査過程에서 發生하는 各種 誤差를 最少限으로 줄일수 있는 最終的인 機會이므로 이를 철저히 실행하지 않으면 안되며 審査를 担当하는 사람은 調査業務에 經驗이 있고 이에 精通한 사람이어야 한다.

(2) 符号化 (Coding)

調査票 審査에 뒤따르는 作業은 符号化 作業이다. 이것은 調査票의 各 調査項目에 對하여 記入된 回答을 몇개의 구로로 分類하고 그 구로에 対応한 一定한 符号를 各 調査票에 부쳐서 分類 集計에 便利하게 하는 作業이다. 따라서 符号化에 앞서서 分類基準이 定하여져 있지 않으면 안되는데 이 分類基準은 企劃過程에서 미리 決定되는 것이 普通이지만 調査項目에 따라서 調査結果를 보지 않고는 適當한 分類基準을 定할 수 없는 것도 있으므로 이러한 경우에는 審査가 끝난 調査票를 하나 하나 檢

討하여 事後에 適當한 分類基準을 定하여야 하는 것이다.

그리고 分類基準이 定하여지면 이에 対応한 符號를 決定하여야 한다. 그런데 符號는 機械集計를 하는 경우와 手集計를 하는 경우에 따라서 若干 相異하다. 機械集計에 있어서의 符號는 1, 2, 3, 9, 0, X, Y의 10數字, 2文字의 範圍에서 選擇하지 않으면 안된다. 이때 1, 2, 3, . . . 으로 적는 數字를 順次로 使用하고 9를 「其他」, X를 「不明」, Y를 「非該」하는 式으로 끝 數字와 文字를 特定한 範圍에 該當시키는 것이 普通이다. 手集計에 있어서는 記入이 簡便하고 判讀하기 쉬운 것이면 어떤 數字나 文字를 使用하여도 좋으나 一見하여 그 範圍의 內容이 聯想되는 것이면 더욱 좋다. 예컨대 性別에 있어서 男性을 m, 女性을 f로 表示하는 것이다.

또 集計에 있어서 가까이 있는 項目과 錯誤하지 않도록 數字가, 나, 다, 大文字, 少文字의 「알파벳」를 섞어서 使用하는 것도 좋은 方法이다. 符號가 決定되면 具體적으로 어디에 무슨 符號를 부치는 가를 細密하게 指示한 符號集을 作成하여 符號記入者에게 나누어 주어 審査가 끝난 調査票에 매장마다 符號를 부치도록 한다. 符號記入者는 符號集에 따라 各 項目의 符號欄에 色鉛筆(色은 統一하여야 한다)로 符號를 記入한다. 이 作業이 끝나면 다른 符號 記入者가 바꾸어서 符號가 제대로 記入되어 있는가 檢査하지 않으면 안된다.

符號化 作業은 項目에 따라서는 매우 쉬운것도 있으나 때로는

매우 어려운 것도 있어 아무리 符号集이 細密하게 되어 있다고 하더라도 具體적인 境遇에 어떤 符号를 부쳐야 할지 困難할 때가 많다. 따라서 符号記入者는 相當한 知識과 熟練을 必要로 하며 注意 깊은 作業을 하여야 하는 것이다. 아무리 完全하게 蒐集된 資料라도 符号化를 잘못하면 그 結果는 쓸모없는 것이 되고 마는 것이다.

그런데 以上은 모두 事後符号化의 경우이나 分類基準과 符号가 調査企劃 過程에서 決定되고 그 基準에 따라 分類(구분化)하기가 매우 쉬운 境遇에는 符号記入을 調査員에게 시키는 境遇가 많은데 이 경우에는 實查를 始作하기 前에 調査員에 對한 철저한 訓練이 있어야 하며 또 事後에 檢査가 따라야 할 것이다.

(3) 集計

調査票 審査와 符号化 作業이 끝나면 모든 調査票를 符号에 따라 分類하여야 한다. 集計란 調査票의 各 項目에 記入된 內容은 計算하는 作業을 말하는 것이다.

集計에는 다음과 같은 種類가 있다.

(가) 單純集計와 相關集計

이것은 만들어지는 統計表의 種類에 依한 分類인데 單純集計란 一般的인 度数分布表를 만드는 集計를 말하며 相關集計는 2個以上の 標識에 關하여 度数를 나타낸 相關表를 만드는 集計를 말한다.

(나) 中央集計와 地方集計

中央集計란 調査票를 中央에 送付케 하여 中央에서 一括集計하는 것을 말하며 地方集計는 調査票를 中央에 送付하지 않고 地方調査機關에서 集計하여 作成된 統計表만을 中央에 送付되어 中央에서 各地로부터 收集된 統計表를 取合하여 最終적인 것을 만드는 方法이다. 地方集計의 唯一한 利點은 集計가 迅速하게 끝난다는데 있으나 機械集計가 發達된 現在에는 地方集計를 하여야 할 理由가 없으며 또 地方集計는 正確性を 欠하기 쉬운 致命的인 결함이 있는 것이다.

(다) 手集計와 機械集計

手集計란 統計機械를 使用하지 않고 사람의 손으로써 集計하는 方法이며 機械集計란 一部の 統計機械를 使用하여 集計하는 方法을 말한다. 手集計는 다시 여러 가지 方法이 있는데 大體로 調査票를 그대로 集計作業에 使用하는 方法과 調査票의 內容을 다른 集計用 카아드에 転記하여 集計하는 方法으로 나눌 수 있다.

機械集計는 電子計算組織에 依한 集計인데 調査票 한장 (또는 一部)마다 펀치 카아드 (punch card)를 만들어 이를 펀치에 依하여 分類하고 다시 計算하는 것이다. 手集計와 다른 點은 펀치 카아드의 充公부터 始作하여 카아드의 分類, 카아드의 計算에 걸쳐 一切의 機械에 依하여 이루어지며 따라서 操作이 매우 迅速, 正確하게 行하여진다는 것이다. 機械集計와 手集計와의 優劣은 한마디로 말할 수 없으나 手集計는,

- (a) 集計가 單純할 때
- (b) 調査対象이 적을 때
- (c) 分類가 極히 細分되어 分類된 各 구룹의 調査票 枚數가 적을 때 等に 有利하고, 機械集計는,
- (a) 調査対象이 많을 때
- (b) 集計가 比較的 複雑할 때
- (c) 網羅的인 集計를 할 때 等に 有利하다.

3.4 統計表의 作成과 分析

(1) 統計表의 種類

調査票의 分類 集計가 끝나면 마지막으로 統計表를 作成하여야 한다. 統計表는 一連의 統計調査 業務의 最終 生産物로서 統計의 作成과 利用의 매개물이 되는 것이므로 統計資料의 觀察 比較, 解釋이 容易하도록 調査에서 收集된 資料(統計數字)를 体系있게 分類하고 簡潔하게 行과 列(欄)로 排列, 整理하여서 다른 說明을 듣지 않더라도 그 表만 보고 調査結果를 把握할 수 있도록 그 構成을 考慮하여야 한다.

統計表의 構成은 統計者의 優劣을 左右하기도 하지만 또한 集計 諸表의 全過程을 규제하게 되는 것이므로 企劃過程에서 가장 먼저 考慮되고 決定되어야 하는 것이다. 그런데 統計表는 그 表示方法

形式内容(性質), 統計数字의 加工여부 等에 따라 다음과 같이 分類할 수가 있다.

(가) 文中統計表와 正式統計表

이것은 統計를 表示하는 方法에 依한 分類인데 文中統計表는 文章中 表示한 統計表로서 表題가 없고 文章과 直接 關係되어 있어 文章을 읽지 않으면 統計의 意味를 알 수 없는 統計表이다. 即, 獨立性이 없는 統計表이다.

이에 對해서 正式統計表는 表題, 表頭, 表例等 表의 體制를 完備하여 다른 說明을 듣지 않더라도 그 表만 보고 內容을 알 수 있고 여러가지 分析이 可能하도록 作成된 統計表이다. 普通 統計表라고 할 때는 이 正式統計表를 말하는 것이다.

(나) 單純分類表와 相關表

이것은 形式에 依한 分類로서 但 한가지의 分類에 依하여 作成된 統計表를 單純分類表라 하며 數種의 分類을 結合하여 만든 統計表를 相關表라고 한다.

(다) 構造統計表와 系列統計表

이것은 統計表의 內容에 依한 分類로서 構造統計表는 時間과 場所를 一定하게 하고 其他 標識(例 産業分類, 規模, 性別等)에 依하여서 分類하여 놓은 統計인데 이를 普通 度數分布表라고도 한다. 例를 들면 業種別, 規模別, 生産額, 또는 性別, 職業別, 従業員數 等の 統計表가 이에 속한다. 이에 對하여 系列統計表는 同種의 統計数字를 時間的 또는 場所的으로 排列한 統計表로서 例컨대 年度別 生産額 또는 道別 從事員數 等の 統計表가 이에 속

한다.

이 中 特히 時系列表는 어떤 現象의 時間的인 變遷을 表示하기 爲한 것으로서 生産指數, 物價指數 等과 같이 指數化 하여 表示되는 경우가 많다.

(라) 非加工 統計表와 加工統計表

이것은 統計數字의 加工 与否에 依한 分類로 非加工 統計表는 統計調査 結果 蒐集된 資料의 總和值(合計值)를 아무런 加工없이 그대로 表示한 統計이며 加工統計表는 非加工統計表에 나타난 統計數字(總和值)를 各種 比率, 平均 等으로 加工하여 表示한 統計表이다. 普通 統計調査 過程은 非加工統計表를 作成 公表하는 것으로 一段落되지만 利用者를 爲하여서는 보다 一目瞭然하게 알 수 있는 加工統計表를 作成하여 表示하여 주는 것이 親切하다.

例를 들면 各種 指數나 國民所得 等이 加工統計表에 속한다.

(2) 統計表의 構成

統計表(正式統計表)는 實質的 要素가 되는 統計數字를 除外하면 다음과 같은 8個의 部分으로 構成된다.

(가) 表 題 (heading)

(나) 頭 註 (headnote)

(다) 表 頭 (box head)

(라) 表 側 (stub)

(마) 欄 (column)

(바) 行 (Line)

(사) 表 体 (field or body)

(아) 脚 註 (foot note)

正 式 統 計 表 의 構 造

表 題 (頭 註)

	表 頭			
表	-	-	-	-
	-	表	体	-
側	-	-	-	-
	-	-	-	-

脚 註 .

1) 表題는 다시 番号表와 表名으로 成立된다. 表番号는 統計表 表의 番号인데 이것은 한 統計表의 系列中에 있어서의 그 統計表의 關係位置를 表示하는 것이며 또 統計表의 索引도 되는 것이다.

따라서 單獨의 統計表에는 番号表를 붙일 必要가 없다. 表名은 表頭의 中心을 이루는 것으로서 統計表 內容의 目錄이다. 表名에는 統計의 表示範圍, 分類事項, 地域的範圍, 基準時点 등이 表示되어야 하며 이 네개의 事項이 綜合되지 않으면 完全한 目錄의 役割을 할 수 없는 것이다.

2) 頭註는 表題와 統計表의 最上位線 사이에 表示되는 注

意事項이나 頭註는 表名을 補充하고 統計表 全体를 理解하는데 必要한 事項으로서 表名과 密接한 關係를 갖는 것이다. 따라서 普通 頭註로서 表示되는 것은 그 統計表의 數字 全体에 關한 單位라든가 統計의 基本時点 또는 統計對象 範圍와 같은 것이다. 頭註가 統計表 全体에 關한 注意事項인데 對하여, 脚註는 表中의 特定한 統計數字 또는 表頭 表側의 意味를 明白히 하거나 資料의 出處를 밝히는데 使用되는 것이다.

脚註는 統計表의 最下位線 아래에 記入한다. 그리고 頭註를 記入할 때는 「註」, 「備考」等を 表示할 必要가 없지만 脚註는 반드시 「註」라고 表示한 다음에 必要事項을 記載하여야 하며 또한 說明을 必要로 하는 數字의 앞(또는 뒤)에는 合符號를 붙여서 註와 連結시켜야 한다.

3) 表頭와 表側은 形式的으로 統計表의 모양을 만들고 實質的으로는 統計系列을 만들어 數字間의 關係를 明白하게 하는 것이다. 表頭는 統計表의 제일 위쪽에 位置하여 各 分類事項을 表示하며 表側은 統計表의 左側에 位置하여 이 亦是 分類事項을 表頭와 表側의 어느쪽에 表示하는 것이 數字間의 關係를 보다 明確하게 나타내는가 그리고 地面을 浪費하지 않고 合理的으로 利用할 수 있는가 하는 것이다.

4) 表體는 統計表中 統計定數가 記入되는 場所를 充칭하는 것으로서 이것은 다시 欄과 行으로 成立된다. 欄은 統計數字가 縱으로 排列되는 것이며 行은 統計數字가 橫으로 排列된 것을 말한다.

(3) 統計表 作成上の 注意

統計表는 社会的으로 널리 利用되므로서 비로서 그 価値가 있는 것이므로 먼저 利用者에게 쉽고 便利하도록 作成되어야 한다. 即, 統計表는 統計利用자가 그 統計表를 보고 理解할 수가 없거나 誤解 또는 錯覺을 이르기도록 複雑하게 만들어져서는 안되며 되도록 簡潔하고 明確하게 作成되어야 한다. 그리고 보다 利用者에게 親切하기 위하여서는 比率, 指數, 平均等 加工統計를 아울러 表示하여 주거나 統計圖表化하여 나타내 주는 것도 좋다.

統計表 作成에 있어서 또 한가지 注意하여야 할 事項은 統計表에는 어떤 個人의 秘密이 露出되어서는 안된다는 것이다. 따라서 分類가 細分되므로써 어떤 個人에 關한 事實이 露出될 우려가 있는 것은 技術的으로 적절히 處理하여 個人의 秘密이 나타나지 않도록 하여야 한다.

그리고 特히 誤解하기 쉬운 事項이 있거나 例外的인 事項이 있는 경우에는 반드시 그 內容을 朱書하여야 한다.

統計表의 一般的인 記載方法은 다음과 같다.

(a) 該當事項이 없을 때는 「-」로 表示한다.

(b) 未詳인 때는 「...」로 表示한다.

(c) 單位未滿인 때 即, 表示單位가 千원인데 集計된 金額이 100 원 또는 300 원이 되었을 때는 「0」으로 表示한다.

끝으로 調查結果를 發表할 때에는 調查目的, 範圍, 調查單位, 調查項目의 定義 調查方法, 標本調査일 때는 標本數, 標本抽出方法等

統計表를 利用하는 사람들이 参考하여야 할 事項에 對한 說明書를 統計表의 앞에 붙여야 한다.

(4) 統計表의 分析

統計表가 作成되면 마지막으로 統計表의 分析이 남는다.

統計表의 分析은 우선 統計表를 알기 쉽게 꾸미고 說明을 加하여 어떤 結論을 끌어내는 것이다. 먼저 統計表를 알기 쉽게 꾸미는데는 統計表의 數字를 加工하여 百分率이나 比率로 나타내는 方法이 있다. 그러나 百分率이나 比率은 아무 數字에 對하여서나 마구 算出하여서는 안된다.

統計表를 分析할 때에는 다음 事項을 檢討하여야 한다.

- (가) 가장 重要한 點은 무엇인가
- (나) 그밖에도 무엇이 表示되어 있는가
- (다) 平均은 豫期한 것 또는 다른 資料에 比하여 어떠한가
- (라) 各 範疇의 最大數나 最小數는 무엇을 意味하는가 다른것과 比較하여 그 百分率은 무엇을 말하는가
- (마) 一般的인 傾向이 있는가 없는가 그것은 어째서 그러한가 例外的인 것은 무엇을 意味하는가
- (바) 因果的인 關係가 나타나는가
- (사) 이미 알려져 있는 것이나 다른 統計表에 나타나 있는 것과 比較하여 一貫性이 있는가.
- (아) 이러한 結果가 나온 것은 標本抽出의 方法이나 調査方法 때문이 아니겠는가

(가) 各 部分의 数字가 다시 檢討하기 위하여 調査票를 찾아 보아야 하거나 再集計를 하는 편이 낫지 않을까.

以上과 같이 檢討하면서 分析하여 가면 重要的 類似性이나 差異, 連續關係, 因果關係가 發見되어 数字의 限界도 明白하게 될 것이다.

그리고 이와같은 檢討와 分析에 이어서 다시 全体的으로 檢討하고 分析하지 않으면 안되는데 이때 重要的 것은 이러한 分析이 先入見에 이끌리어 不當하게 強調되거나 輕視되는 일이 있어서는 안된다. 一般的인 傾向과 例外的인 境遇와를 明確히 區別하고 이에 올바른 評價를 加하여야 하는 것이다. 因果關係를 推論하는 경우에도 單純히 数字上的 相關關係가 있는 것으로 立論하여서는 안되며 넓은 理論的인 考察과 精密한 比較分析이 推論의 前提가 되어야만 한다.

第 4 章 統計調査의 実例 (經濟活動人口調査)

經濟活動人口調査는 1957 年부터 1962 年 5 月까지 地方 行政機關을 通하여 勞動力調査를 實施하여 每月 就業者와 失業者의 資料를 蒐集하였다.

그 後 經濟開發 5 個年計劃의 樹立과 그 遂行을 爲하여 經濟活動에 參與하는 人口의 正確한 資料가 切實히 要請되어 經濟企劃院 調査統計局에서 過去에 實施한 勞動力調査의 諸缺點을 시정하고 보다 正確한 資料를 作成할 目的으로 統計法 第 2 條에 依拠하여 經濟活動人口調査를 指定統計 第 4 号로 定하고 1960 年 人口센서스에 根拠를 둔 새로운 標本設計와 專門化된 調査員에 依하여 1962 年 8 月부터 實施하여 왔다.

그러나 時間이 흐름에 따라 調査区內的 特性値가 變하여 1969 年 6 月부터는 1966 年 人口센서스의 調査区에 根拠를 둔 標本에 依하여 再設計 되었고 다시 1970 年 人口 및 住宅센서스가 實施됨에 따라 1972 年 3 月부터는 이에 依한 새로운 調査地域에서 實施하게 되었다.

다음에 經濟活動人口調査의 概要, 調査節次, 調査票作成, 調査結果에 對하여 前述한 調査方法에 依拠 紹介함으로써 理解를 돕고자 한다.

4. 1 調査概要

(1) 調査目的

經濟人口 및 諸社会与件의 變動에 따르는 國民의 經濟活動의 變化를 適期에 正確히 把握하여 雇傭 및 失業의 構造와 變動推移를 分析하고 이에 對한 政策을 樹立하는데, 基礎資料를 提供하는데 그 目的이 있다.

(2) 調査範圍

調査期間을 基準으로 하여 大韓民國 國籍을 가진 常住人口의 1 / 500 에 該當하는 人口中 滿 14 歲 以上者는 모두 調査對象者로 하나 다음 事項에 該當되는 者는 除外한다.

(가) 現役軍人

(나) 刑이 確定된 교도소 수감자

(다) 外國人

常住者라 함은 調査期間을 基準으로 하여 同一한 場所에서 3 個月 以上 居住하였거나 居住하려는 期間이 3 個月에 達하는 者를 말한다.

但, 航空, 船舶의 船員은 長期 出他中일지라도 調査한다.

(3) 調査項目

本 調査의 調査票는 18 個 調査項目으로 되어 있는데 姓名等 6 個項目의 人的事項과 1 週間の 主된 活動狀態等 12 個項目의 經濟活動事項을 調査한다.

(4) 調査方法

(가) 標本調査

1970年 人口 및 住宅센서스 調査区中 普通調査区에서 1/500에 該当되는 市部 72個 調査区和 郡部 93個 調査区等 總 165個 調査区를 抽出하여 同 調査区内的 全家口 約 12,000 標本家口를 調査하는 標本調査이며 標本抽出에서 除外된 調査区는 落島 閑地 調査区, 寄宿舍 調査区, 特殊社会施設 調査区, 特別 調査区 등이며 除外된 調査区의 센서스 人口는 約 75 萬名에 不過하다.

(나) 週間 및 家口单位調査

經濟活動人口調査는 1週間の 調査期間中에 일어나는 經濟活動狀態를 把握하는 方法으로 家口를 標单位로 調査하고 있다.

調査期間을 1週間으로 定한 理由는 1週間이란 質問時 応答者の 記憶誤差를 적게 하여 正確한 応答를 바랄 수 있고 經常狀態의 變動을 充分히 避할 수 있기 때문이다.

(다) 面接調査方法和 配票調査 方法의 併用

經濟活動人口調査票는 対象家口를 訪問하여 応答者로부터 얻어지는 정보를 調査員이 記入하는 他計式方法을 使用하며, 就業時間 記入票를 応答者 自身이 記入하는 自計式方法을 쓰고 있다.

(5) 調査時期

季節別로 1년에 4번 実施하며 調査対象期間(調査週間)은 指定된 달(3月, 6月, 9月, 12月)의 指定된 1週間으로 하여

實際 調査期間 (実査期間) 은 調査週間 다음의 1 週間으로 한다.

1972 年の 調査時期는 다음과 같이 計劃하고 있다.

	準備 調査	調査週間	実地 調査
1 / 4 分期 (3 月)	5 日 ~ 11 日	12 日 ~ 18 日	19 日 ~ 25 日
2 / 4 分期 (6 月)	4 日 ~ 10 日	11 日 ~ 17 日	18 日 ~ 24 日
3 / 4 分期 (9 月)	3 日 ~ 9 日	10 日 ~ 16 日	17 日 ~ 23 日
4 / 4 分期 (12 月)	3 日 ~ 9 日	10 日 ~ 16 日	17 日 ~ 23 日

(6) 主要用語定義

(가) 家 口

居住와 家計를 같이 하는 사람의 모임을 家口라 하며 한 사람이라도 別途로 居住하고 独立的인 家計를 이룩하고 있는 境遇에는 하나의 家口로 간주한다.

1 家庭婦, 其他使用人, 店員, 同居人等은 主家口の 家口員으로 包含시킨다.

2 賃房인 同居人으로서 主家口와는 家計를 別途로 하는 境遇와 食事는 같이 하고 있지만은 主家口에게 房賃라든가 食費를 支払하여 家計를 別途로 하는 사람은 主家口の 家口員에 包含시키지 않고 別個의 家口로 한다.

그러나 친척이라든가 主人의 子弟를 돌보아 주고 実費程度의 食費, 房賃를 받고 있는 同居人은 主家口の 家口員으로 한다.

3 学校나 工場等の 寄宿舎等에서 살고 있는 独身者는 各各 単一 家口로 하였으나 이 때 全員이 한 家族처럼 살고 있으면 그 家口一員을 하나의 家口로 한다.

(나) 農 家

農家라 함은 農業을 生業(生計와 營利)으로 하는 家口로 서 다음 各 号의 1에 該当하는 家口를 말한다.

1 所有如何를 不問하고 논, 밭, 水源池等の 總面積이 300 坪 以上을 直接 耕作하는 境遇

2 大家畜(소 또는 말)을 1마리 以上 飼育하는 境遇
(但 運搬用은 除外)

3 中家畜(돼지, 염소, 羊等)을 도합 3마리 以上 飼育하는 境遇

4 小家畜(토끼等)을 40마리 또는 닭 30마리 以上을 飼育하는 境遇

5 高等園芸, 菜蔬, 特用作物等 100 坪 또는 果樹苗圃等を 200 坪 以上 耕作하는 境遇


6 5 郡 以上の 養蜂을 하는 境遇

7 蚕種 10 9 以上을 소잡하는 境遇

農業과 他産業을 함께 經營하는 境遇에는 農業收入이 50 % 以上인 境遇에만 農家に 包含시킨다. (但 農業收入面으로 區別하기 困難할 때에는 勞動力 投入量으로 區別한다)

(다) 經濟活動人口

財貨나 用役을 生産하기 爲하여 勞働을 提供하는 모든 사람과 提供할 能力이 있는 사람을 말한다.
여기에는 다음과 같은 種類로 分類된다.



(7) 調査結果

經濟活動人口調査의 結果表는 다음 9個表로 되어 있으며

經濟活動人口年報에 公表한다.

- (가) 經濟活動人口年報
- (나) 年齡階級別 經濟活動人口
- (다) 非經濟活動人口
- (라) 年齡階級別 就業者
- (마) 産業 및 年齡階級別 就業者
- (바) 産業別 就業者
- (사) 職業別 就業者
- (아) 從事上의 地位別 就業者
- (자) 産業 및 就業時間別 就業者

4 . 2 調査節次

(1) 準備調査期間

準備調査期間에는 먼저 標本으로 뽑힌 調査區의 要圖를 作成하고 要圖에 나타난 居處에 居住하는 家口의 家口員名簿를 作成한다.

調査區要圖와 家口員名簿는 本 調査의 基本이 되는 것으로서 要圖는 正성을 다하여 깨끗하고 正確하게 作成하여야 하며 名簿는 每 家口마다 빠짐없이 作成하여야 함으로 사람이 살 수 있는 곳은 全部 確認한다.

調査區要圖의 作成要領은 먼저 地形 地物의 表示를 補充記入하면

서 境界線을 確認 作成하고 調査區 境界線과 境界線 안쪽에 있는 道路와 建物(또는 居處)을 빠짐없이 口로 그려 넣고 主要建物の 이름이나 地名을 써넣어 位置를 明確히 한 다음 居處의 一連番號를 口안에 調査하기 便利한 順序로 記入한다.

調査區要圖와 家口員名簿가 作成되면 調査員은 調査區를 수시로 순회하며 新築建物(居處)과 建物の 撤去等 地形 또는 建物の 變動을 把握하여 要圖를 補完 修正하여야 하며 또한 家口員名簿作成後 每 訪問時마다 家口 및 家口員의 變動事項을 把握하여 要圖 및 家口員 變動報告書에 記入하여 다음 実査에 漏落이나 重複이 없도록 事前 準備를 하여야 한다.

또한 準備調査期間에 就業時間 記入表를 配付하여 被調査者가 經濟活動狀況을 事前 記入토록 하여 調査上 便宜와 正確을 期할 수 있도록 한다.

(2) 調査週間

調査週間은 調査対象이 되는 1週間으로서 準備調査期間에 配付한 就業時間記入表를 正確하게 作成하고 있는가의 与否를 確認하고 萬若 記入上の 애로가 있을 境遇 이를 指導하여 正確하게 作成되도록 한다.

또한 就業時間記入 確認中 調査區要圖와 家口員의 變動이 있을 境遇 繼續하여 補完하고 이를 變動報告書에 記入하여 中央에 報告토록 한다.

(3) 実査期間

実査期間은 調査週間 다음 1 週間으로서 各 家口の 満 14 歳 以上 人口인 各 사람과 直接面談하여 調査票를 記入하되 準備 調査時 配付하여 被調査者가 作成한 就業時間記入票를 比較하여 作成토록 한다.

実査期間에도 調査区の 要図와 家口員名簿를 補完하여 調査의 漏 落을 防止하고 次期調査를 便利하게 한다.

調査票의 項目別 作成要領은 다음에 説明토록 한다.

(4) 整理期間

整理期間은 実査가 完了된 後 調査의 正確性を 把握하는 期間으로서 우선 變動報告書의 記入內容을 確認하여 調査의 重複이나 漏落을 檢討하고 各 調査票의 內容을 檢査하여 調査票作成이 잘 되었는가 살핀 다음 各 調査區別 綜合表를 作成토록 한다.

4 . 3 調査票作成

(1) 調査員의 態度

(가) 調査員의 身分을 確認할 수 있는 身分証을 반드시 提示한다.

(나) 各 家口の 満 14 歳 以上 人口인 各 사람과 直接 面談하여 調査하는 것이 原則이다.

(다) 親切하게 自己紹介를 한 後에 經濟活動人口調査의 目的을

說明하고 正確한 答辯을 하여 줄 것을 付託한다.

(라) 調査員이 家口를 訪問하였으나 사람이 없어서 調査를 할 수가 없을 境遇에는 家口員名簿에 表示를 하였다가 再訪問을 하도록 한다.

(마) 調査票記入을 할 때에는 같은 事項 例를 들면 職業이나 産業이 같은 境遇에 「上同」 또는 「#」으로 記入하지 말고 反復하여 記入하되 該当事項이 없는 난에는 「\」을 긋는다.

(2) 調査票의 記入要領

經濟活動人口調査는 經濟活動人口를 對象으로 하고 있으므로 家口員中 14歲 以上인 者에 對하여서만 調査토록 한다.

調査項目은 이름等 6種의 人的事項과 活動狀態等 12種의 經濟活動事項이며 第7欄의 「지난 1週日間に 주로 무엇을 하셨습니까?」에서는 지난 1週間に 주로 한 行為란 平常時에 했던 活動과는 關係없이 指定된 週間 사이에 活動한 行為를 말하는데 9個의 項目中 「1. 일하였음」에 「○」表한 사람은 8欄, 9欄, 10欄은 「\」을 긋고 11欄부터 質問하며 其外項目의 境遇 8~10欄을 作成토록 한다.

다음에 調査票의 項目을 묻는 方法의 次例를 圖表로 나타냈으며 經濟活動人口調査票 作成 例를 添附하여 參考토록 하였다.

4.4 調査方法決定의 理論的 基礎

勞動力調査方法은 資料蒐集上的 接近法과 概念上的 接近法이 있다.

(1) 資料蒐集上的 接近法

資料蒐集上的 接近法에는 事業체를 調査對象으로 그 事業체에 雇傭되어 있는 被雇傭者와 그와 關聯된 資料를 蒐集하는 事業体 接近法과 家口를 調査對象으로 하여 就業者, 失業者 및 其他 人口學的 特性值를 家口內的 家口員과 關聯하여 資料를 蒐集하는 家口 接近法이 있다.

事業体接近法은 被雇傭人의 數를 비롯하여 給与, 賃金, 就業할 計劃, 時間 및 日數, 實際 就業한 時間等 有用한 資料를 同時에 얻을 수 있고 얻어진 資料는 雇傭指數, 賃金(日, 週, 月別)指數, 産業間의 移職率은 얻을 수 있으며 産業, 職業, 性別 就業者의 構成은 調査期間中 就業模型의 變化를 測定할 수 있는 長點이 있으나 調査期間中 한 事業体 以上에 일한 者는 모두 그곳에서 把握되므로 過大로 調査되기 쉬우며 오직 被雇傭者에 限하여 調査되므로 調査의 範圍가 限定되어 있어 雇傭主, 自營業主, 家族從事者, 失業者, 非經濟活動人口等은 把握할 수 없는 短點이 있다.

家口接近法은 就業者, 失業者, 非經濟活動人口의 特性을 모두 把握할 수 있으며 이를 特性值와 結付하여 家口의 社會的, 經濟的, 人口學的 背景을 同時에 研究할 수 있는 長點이 있으며 正確한

給与額이나 賃金率을 算出할 수 없으며 生産量이나 生産性を 把握할 수 없는 短点이 있다.

(2) 概念上の 接近法

調査의 概念上 接近法에는 平常狀態에서 주어진 役割이나 機能에 依하여 勞動力人口를 調査를 하는 有業者接近法과 어떤 期間内に 實際로 活動한 狀態에 依하여 勞動力人口를 調査하는 勞動力接近法이 있다.

有業者接近法은 職業이 있느냐 없느냐로 就業者와 그 밖에 것으로 区分하기 쉽고 調査員訓練이 容易하며 平常狀態에 依하여 얻어진 資料이기 때문에 季節的이나 우발적인 活動에 別로 影響을 입지 않는 長点이 있고 한가지 職業이나 確固不同한 職業이 없는 者들을 定義하기 어려운 同時에 얻어진 結果는 特定한 期間이 없기 때문에 Bench Mark로 使用하기에 不適當하고 처음 求職活動을 한 者를 失業者로 捕捉하기 힘들며 또한 經濟的 經濟動向을 捕捉할 수 없는 短点이 있다.

勞動力接近方法은 짧은 期間동안 일어난 活動을 묻기 때문에 記憶誤謬를 적게 하고 Bench Mark로 提供될 수 있으며 經常狀態는 平常狀態보다 客觀的이고 正確性を 期할 수 있고 失業者, 非經濟活動人口를 쉽게 區別할 수 있을뿐 아니라 經常的 經濟動向을 빨리 捕捉할 수 있는 長点이 있고 反面에 짧은 期間에 일어난 活動狀態를 調査하므로 그 期間中에 우발사건이나 氣候變動이 일어났을

때 그 影響이 크게 미치게 되어 繼統적으로 調査하여야 한다는 短點을 가지고 있다.

(3) 以上の 두 方法에 對하여 UN에서도 勸告하고 있으나 어느 方法을 採하여야 할지는 調査의 性格이나 그 나라의 經濟的, 社會的 條件에 依하여 左右된다.

우리 나라의 經濟活動人口調査는 就業者, 失業者, 非經濟活動人口의 構成的 特性을 모두 把握할 수 있는 家口接近法과 客觀적이고 正確性을 期할 수 있는 勞動力接近方法에 依拠 實施되고 있다.