

### 3.4 표본배정

$n, n_h$ 를 배정해야한다.

#### 3.4.1 모평균의 추정

$$z_{\alpha/2} \sqrt{\text{Var}(\bar{y}_{st})} = B \Rightarrow \text{Var}(\bar{y}_{st}) = \left( \frac{B}{z_{\alpha/2}} \right)^2 \equiv D$$

$$\begin{aligned} \text{Var}(\bar{y}_{st}) &= \sum_{h=1}^H \left( \frac{N_h}{N} \right)^2 \left( \frac{N_h - n_h}{N_h - 1} \right) \frac{\sigma_h^2}{n_h} \approx \sum_{h=1}^H \left( \frac{N_h}{N} \right)^2 \left( \frac{N_h - n_h}{N_h} \right) \frac{\sigma_h^2}{n_h} (N_h - 1 \approx N_h) \\ &= \sum_{h=1}^H \left( \frac{N_h}{N} \right)^2 \left( \frac{N_h - n_h}{N_h} \right) \frac{\sigma_h^2}{n_h} (w_h = n_h/n) \end{aligned}$$

$$\Rightarrow n = \frac{\sum_{h=1}^H N_h^2 \sigma_h^2 / w_h}{N^2 D + \sum_{h=1}^H N_h \sigma_h^2}$$

□ 층 배정물의 결정방법 ?

- 비용함수( cost function)  $C = c_0 + \sum_{h=1}^H c_h n_h = \sum_{h=1}^H c_h n_h$  (가정 :  $c_0 = 0$ )

※ 비용조건을 만족하고  $\text{Var}(\bar{y}_{st})$ 가 최소가 되도록 결정

▪ 라그랑주 승수법( Lagrangian multiplier method)

$$f(n_1, \dots, n_H) = \sum_{h=1}^H \left( \frac{N_h}{N} \right)^2 \left( \frac{\sigma_h^2}{n_h} \right) \left( \frac{N_h - n_h}{N_h} \right) = \text{Var}(\bar{y}_{st})$$

$$g(n_1, \dots, n_H) = C - \sum_{h=1}^H c_h n_h = 0$$

$$L = \text{Var}(\bar{y}_{st}) - \lambda (C - \sum_{h=1}^H c_h n_h)$$

$$\frac{\partial L}{\partial n_h} = 0 \Leftrightarrow -\frac{N_h^2 \sigma_h^2}{N^2 n_h^2} + \lambda c_h = 0 \Rightarrow n_h = \frac{1}{\sqrt{\lambda}} \frac{N_h \sigma_h}{N \sqrt{c_h}}$$

$$\sum_{h=1}^H n_h = n \Rightarrow \sqrt{\lambda} = \frac{1}{nN} \sum_{h=1}^H \frac{N_h \sigma_h}{\sqrt{c_h}}$$

$$n_h = \left( \frac{N_h \sigma_h / \sqrt{c_h}}{\sum_{h=1}^H N_h \sigma_h / \sqrt{c_h}} \right) n \quad \left( \text{즉, } n_h \propto \frac{N_h \sigma_h}{\sqrt{c_h}} \right), \text{ 층이 크거나, 층내분산이 크거나, 관측비용이}$$

적게 들면 그 층의 표본크기를 늘리는 것이 좋다는 의미.

요인은 층크기, 층내변동, 층별 관측비용

▪ 최적배정(optimal allocation)

$$n = \frac{\left( \sum_{h=1}^H N_h \sigma_h / \sqrt{c_h} \right) \left( \sum_{h=1}^H N_h \sigma_h \sqrt{c_h} \right)}{N^2 D + \sum_{h=1}^H N_h \sigma_h^2}$$

- 네이만 배정(Neyman allocation) ( $c_h = c$ , 층별단위 관측비용을 전부 같게 놓는 경우)

$$n_h = \left( \frac{N_h \sigma_h}{\sum_{h=1}^H N_h \sigma_h} \right) n, \quad n = \frac{\left( \sum_{h=1}^H N_h \sigma_h \right)^2}{N^2 D + \sum_{h=1}^H N_h \sigma_h^2}$$

- 비례배정(proportional allocation) ( $n_h \propto N_h$ )

$$n_h = \left( \frac{N_h}{N} \right) n, \quad n = \frac{\sum_{h=1}^H N_h \sigma_h^2}{ND + \sum_{h=1}^H N_h \sigma_h^2 / N}$$

- 동등배정(equal allocation)

$$n_h = n/H$$

예 3.5 남녀별 층화표집으로 학생들이 한 학기동안 읽은 책의 평균 권수를 조사하려고 한다. 최대 오차  $\pm 2$ 로 표본을 최적배정하라.

층	$N_h$	$\sigma_h$	$c_h$
남학생	212	10	1
여학생	88	5	2
합계	300		

항목	남학생	여학생	합계
$N_h\sigma_h/\sqrt{c_h}$	2120	311.13	2431.13
$N_h\sigma_h\sqrt{c_h}$	2120	622.25	2742.25
$N_h\sigma_h^2$	21200	2200	23400
$w_h$	0.872	0.128	1

$$\text{Var}(\bar{y}_{st}) = D = \left( \frac{B}{z_{\alpha/2}} \right)^2 = 1$$

$$n = \frac{\left( \sum_{h=1}^H N_h\sigma_h/\sqrt{c_h} \right) \left( \sum_{h=1}^H N_h\sigma_h\sqrt{c_h} \right)}{N^2D + \sum_{h=1}^H N_h\sigma_h^2} = 58.8 \approx 59$$

$$n_h = \left( \frac{N_h\sigma_h/\sqrt{c_h}}{\sum_{h=1}^H N_h\sigma_h/\sqrt{c_h}} \right) n \quad n_1 = 0.872 \times 59 = 51.3, \quad n_2 = 0.128 \times 59 = 7.53$$

예 3.6 조사비용이 50만원밖에 없다.

$$C = c_0 + \sum_{h=1}^H c_h n_h = \sum_{h=1}^H c_h n_h \quad (\text{가정 : } c_0 = 0)$$

$$c_1 n_1 + c_2 n_2 = 1n_1 + 2n_2 = 50, \quad n w_1 + 2n w_2 = (0.872)n + 2(0.128)n = 50 \quad (n_h = n w_h)$$

$$n = 44.3 \approx 44, \quad n_1 = 44(0.872) = 38.4, \quad n_2 = 44(0.128) = 5.6$$

예 3.7 (비례배정)

$$n = \frac{\sum_{h=1}^H N_h\sigma_h^2}{ND + \sum_{h=1}^H N_h\sigma_h^2/N} = \frac{23400}{300(1) + \frac{1}{300}(23400)} = 61.9$$

$$n_h = \left( \frac{N_h}{N} \right) n, \quad n_1 = 62 \times \left( \frac{212}{300} \right) = 43.8, \quad n_2 = 62 \times \left( \frac{88}{300} \right) = 18.2$$

### 3.4.2 모함의 추정

$$D = \left( \frac{B}{z_{\alpha/2} N} \right)^2$$

### 3.4.3 모비율의 추정

$$\square n = \frac{\sum_{h=1}^H N_h^2 \sigma_h^2 / w_h}{N^2 D + \sum_{h=1}^H N_h \sigma_h^2}, (\sigma_h = p_h(1-p_h)) \rightarrow n = \frac{\sum_{h=1}^H N_h^2 p_h(1-p_h) / w_h}{N^2 D + \sum_{h=1}^H N_h p_h(1-p_h)} (D = B^2/4)$$

- 최적배정(optimal allocation)

$$n_h = \left( \frac{N_h \sqrt{p_h(1-p_h)}/c_h}{\sum_{h=1}^H N_h \sqrt{p_h(1-p_h)}/c_h} \right) n, \quad n = \frac{\left( \sum_{h=1}^H N_h \sqrt{p_h(1-p_h)}/c_h \right) \left( \sum_{h=1}^H N_h \sqrt{p_h(1-p_h)c_h} \right)}{N^2 D + \sum_{h=1}^H N_h p_h(1-p_h)}$$

- 네이만 배정(Neyman allocation) ( $c_h = c$ )

$$n_h = \left( \frac{N_h \sqrt{p_h(1-p_h)}}{\sum_{h=1}^H N_h \sqrt{p_h(1-p_h)}} \right) n, \quad n = \frac{\left( \sum_{h=1}^H N_h \sqrt{p_h(1-p_h)} \right)^2}{N^2 D + \sum_{h=1}^H N_h p_h(1-p_h)}$$

- 비례배정(proportional allocation) ( $n_h \propto N_h$ )

$$n_h = \left( \frac{N_h}{N} \right) n, \quad n = \frac{\sum_{h=1}^H N_h p_h(1-p_h)}{ND + \sum_{h=1}^H N_h p_h(1-p_h)/N} \leq \frac{N}{4ND + 1}$$

예 3.8 통계인으로 자부심을 갖고 있는냐? “그렇다”. 과거조사에서  $\hat{p}_1 = 0.80$ ,  $\hat{p}_2 = 0.25$ 였다. 최대오차한계를  $\pm 5\%$ 로 유지하고 싶다. 여학생 조사는 남학생보다 2배의 조사 비용이 든다. 총표본수를 결정하고 층별 표본배정을 하자.

항목	남학생	여학생	합계
$N_h$	212	88	300
$N_h \sqrt{p_h(1-p_h)}/c_h$	84.8	26.94	111.74
$N_h \sqrt{p_h(1-p_h)c_h}$	84.8	53.89	138.69
$N_h p_h(1-p_h)$	33.92	16.5	50.42
$w_h$	0.76	0.24	1

$$D = B^2/4 = 0.05^2/4 = 0.000625$$

$$n = \frac{\left( \sum_{h=1}^H N_h \sqrt{p_h(1-p_h)}/c_h \right) \left( \sum_{h=1}^H N_h \sqrt{p_h(1-p_h)c_h} \right)}{N^2 D + \sum_{h=1}^H N_h p_h(1-p_h)} = 145.3$$

$$n_1 = 146(0.76) = 111, \quad n_2 = 146(0.24) = 35$$

예 3.9 조사비용 동일, 모분산 정보 없고, 비례배정시 총표본수

$$n = \frac{N}{4ND+1} = \frac{300}{4*300*0.000625+1} = 172$$

$$n_1 = 172\left(\frac{212}{300}\right) = 121.55, n_2 = 172\left(\frac{88}{300}\right) = 50$$

### 3.5 층의 결정

누적  $\sqrt{f}$  측도 상에서 등간격 구간,  $H$ 는 5개 이하

### 3.6 표본선택 후의 층화-사후층화(poststratification)

가정:  $N_h/N$ 을 아는 경우

$$\bar{y}_{post} = \sum_{h=1}^H \frac{N_h}{N} \bar{y}_h, \quad \widehat{Var}(\bar{y}_{post}) \approx \left(1 - \frac{n}{N}\right) \sum_{h=1}^H \frac{N_h}{N} \frac{s_h^2}{n} + \frac{1}{n^2} \sum_{h=1}^H \left(1 - \frac{N_h}{N}\right) s_h^2 \quad (n \text{이 충분히 크고, } n_h \geq 30)$$

### 3.7 층화를 위한 이중표집(double sampling, 이상표집(two-phase sampling))

$$W_h = \frac{N_h}{N} : \text{층 } h \text{에 떨어진 모집단의 비율}$$

$$w_h = \frac{n_h}{n} : \text{층 } h \text{에 떨어진 첫 번째 표본의 비율} (n_h : \text{확률변수})$$

▼  $n$ 을 얼마?,  $n_h$ 들을 어떻게 결정해야하는지? (Cochran (1977))

▼ 층화용 이중표집(double sampling for stratification)

첫 번째 표집의 목적은 모집단 층비중을 추정, 두 번째 표집의 목적은 층별 모수추정

▪ 모평균  $\mu = \sum_{h=1}^H W_h \mu_h$

$$\bar{y}_{st} = \sum_{h=1}^H w_h \bar{y}_h, \quad \widehat{Var}(\bar{y}_{st}) \approx \sum_{h=1}^H \left[ \frac{w_h^2 s_h^2}{n_h} + \frac{w_h (\bar{y}_h - \bar{y}_{st})^2}{n} \right]$$

▪ 모비율  $p = \sum_{h=1}^H W_h p_h$

$$\hat{p}_{st} = \sum_{h=1}^H w_h \hat{p}_h, \quad \widehat{Var}(\hat{p}_{st}) \approx \sum_{h=1}^H \left[ \frac{w_h^2 \hat{p}_h (1 - \hat{p}_h)}{n_h - 1} + \frac{w_h (\hat{p}_h - \hat{p}_{st})^2}{n} \right]$$

$$(\bar{y}_h = \hat{p}_h, s_h^2 = n_h \hat{p}_h (1 - \hat{p}_h) / (n_h - 1))$$

예 3.10 이 지역에서 불우이웃 돕기 성금을 내는 가구들의 비율을 추정하려고 한다.

$n = 374$  세대주를 단순임의 추출.

종교	성금 0	성금 X	합계 $n = 92$ $n' = 374$
종교신자	43	31	$n_1 = 74$ $n'_1 = 292$ $w_1 = 292/374 = 0.78$ $\hat{p}_1 = 43/74 = 0.58$
무교	14	4	$n_2 = 18$ $n'_2 = 82$ $w_2 = 82/374 = 0.22$ $\hat{p}_2 = 14/18 = 0.78$

$$\hat{p}_{st} = \sum_{h=1}^H w_h \hat{p}_h = 0.624$$

$$\widehat{Var}(\hat{p}_{st}) \approx \sum_{h=1}^H \left[ \frac{w_h^2 \hat{p}_h (1 - \hat{p}_h)}{n_h - 1} + \frac{w_h (\hat{p}_h - \hat{p}_{st})^2}{n} \right] = 0.00252$$

$$95\% \text{ 신뢰구간} : 0.624 \pm 2\sqrt{0.00252} = 0.62 \pm 0.1$$