

표본조사론

2021-15115 권이태

September 12, 2024

Contents

1	표본조사와 추정	3
1.1	표본조사	3
1.2	오차의 분해	3
1.3	Horvitz-Thompson 추정량	3
2	비복원 단순확률추출	6
2.1	비복원 단순확률추출	6
2.2	표본수의 결정	6
3	층화추출	8
3.1	층화추출	8
3.2	층화추출의 표본배정	8
3.2.1	비례배정	8
3.2.2	최적배정	9
3.3	사후층화	10
3.4	층화를 위한 이중표집	10
3.5	부차모집단에서의 비교	11
4	일단계 집락추출	12
4.1	집락 크기가 같은 경우의 일단계 집락추출	12
4.2	표본설계효과	13
4.3	집락 크기가 다른 경우의 일단계 집락추출	14
4.4	평균 추정	15
4.5	총계 추정과 표본 크기의 선택	15
5	이단계 집락추출	16
6	층화집락추출	18
7	비추정과 회귀추정	19
7.1	비추정	19
7.1.1	비추정과 SRS의 비교	20
7.1.2	층화표집에서의 비추정량	21
7.2	회귀추정	22
7.2.1	차이추정	22
8	계통추출	23
8.1	계통추출	23
8.2	반복계통추출	24

8.3 모형을 이용한 추정	24
9 모집단 크기의 추정	25
9.1 포획-재포획 추정	25
9.2 사각표집	26
9.3 임의화 반응	26
10 비균등 확률추출	28
10.1 PPS 추출	28
10.1.1 PPS 집락추출	28
11 분산추정법	29
11.1 선형화 분산 추정법	29
11.2 복제치 분산 추정법	29
12 무응답과 무응답대체법	31
12.1 단위무응답의 처리	31
12.2 항목무응답의 처리	32

Chapter 1

표본조사와 추정

1.1 표본조사

- 전수조사(census): 모든 조사 대상을 조사
 - 정확한 값을 계산할 수 있음
 - 조사비용이 많이 듦
- 표본조사: 일부를 표본으로 뽑아 조사
 - 조사비용이 적고 빠르게 진행할 수 있음
 - 훈련되지 않은 면접원 등으로 인한 비표본오차의 발생 위험이 적음
 - 표본오차의 발생

1.2 오차의 분해

- 비관측오차
 - 포함오차: 표본추출틀(frame)이 목표모집단(population)과 같지 않아 생기는 오차
 - 표본오차: 표본추출틀(frame)에서 일부 표본(sample)만을 관측하기 때문에 발생하는 오차
 - 무응답오차: 추출된 표본(sample)이 응답자(respondents) 집단과 다름에 따라 생성되는 오차
- 관측오차
 - 측정오차: 참값의 부정확한 측정에서 오는 오차; 면접원, 응답자, 도구, 면접 모드의 불완전성
 - 처리오차: 처리 과정에서 발생하는 오차

1.3 Horvitz-Thompson 추정량

Definition 1. 모집단 혹은 조사명부를 $U = \{1, 2, \dots, N\}$ 라 할 때, 표본으로 얻을 수 있는 집합은 $\mathcal{A} = 2^U$ 이다. 표본분포는 \mathcal{A} 에서 정의된 확률밀도함수로,

$$(a) 0 \leq P(A) \leq 1, \forall A \in \mathcal{A}$$

$$(b) \sum_{A \in \mathcal{A}} P(A) = 1$$

을 만족한다.

Definition 2. 일차 표본포함확률 π_i : i 번째 대상이 표본에 포함될 확률

$$\pi_i = P(i \in A) = \sum_{i \in A} P(A)$$

이차 표본포함확률(결합표본포함확률) π_{ij} : i 번째 대상과 j 번째 대상이 모두 표본에 포함될 확률

$$\pi_{ij} = P(i, j \in A) = \sum_{i, j \in A} P(A)$$

Definition 3.

확률표본추출: 모든 $i \in U$ 에 대하여, $\pi_i > 0$ 인 표본추출 방법

가측표본추출: 모든 $i, j \in U$ 에 대하여, $\pi_{ij} > 0$ 인 표본추출 방법

Definition 4. 확률표본추출로 추출된 표본에서 모집단 총계 $Y = \sum_{i=1}^N y_i$ 의 **Horvitz-Thompson(HT)** 추정량은 아래와 같이 정의된다.

$$\hat{Y}_{HT} = \sum_{i \in A} \frac{y_i}{\pi_i}$$

Theorem 1. HT 추정량은 아래의 성질을 만족한다.

$$\begin{aligned} \mathbb{E}[\hat{Y}_{HT}] &= Y \\ \mathbb{V}(\hat{Y}_{HT}) &= \sum_{i=1}^N \sum_{j=1}^N (\pi_{ij} - \pi_i \pi_j) \frac{y_i}{\pi_i} \frac{y_j}{\pi_j} \end{aligned}$$

Proof. 표본포함지시변수 $I_i = I(i \in A)$ 를 정의하면, HT 추정량은

$$\hat{Y}_{HT} = \sum_{i=1}^N \frac{y_i}{\pi_i} I_i$$

으로 주어진다. 한편 $\mathbb{E}[I_i] = \mathbb{E}[I(i \in A)] = \pi_i$ 이므로,

$$\mathbb{E}[\hat{Y}_{HT}] = \mathbb{E} \left[\sum_{i=1}^N \frac{y_i}{\pi_i} I_i \right] = \sum_{i=1}^N \frac{y_i}{\pi_i} \mathbb{E}[I_i] = \sum_{i=1}^N y_i = Y$$

를 얻는다. 마찬가지로, $\text{Cov}(I_i, I_j) = \pi_{ij} - \pi_i \pi_j$ 임을 이용하면

$$\mathbb{V}(\hat{Y}_{HT}) = \sum_{i=1}^N \sum_{j=1}^N \frac{y_i}{\pi_i} \frac{y_j}{\pi_j} \text{Cov}(I_i, I_j) = \sum_{i=1}^N \sum_{j=1}^N (\pi_{ij} - \pi_i \pi_j) \frac{y_i}{\pi_i} \frac{y_j}{\pi_j}$$

을 얻는다. □

Theorem 2. (SYG 분산 공식) 만약 표본수가 일정한 고정표본수 추출의 경우,

$$\mathbb{V}(\hat{Y}_{HT}) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\pi_{ij} - \pi_i \pi_j) \left(\frac{y_i}{\pi_i} - \frac{y_j}{\pi_j} \right)^2$$

와 같이 표현할 수 있다.

Proof.

$$\begin{aligned} \mathbb{V}(\hat{Y}_{HT}) &= \sum_{i=1}^N \sum_{j=1}^N (\pi_{ij} - \pi_i \pi_j) \frac{y_i y_j}{\pi_i \pi_j} \\ &= \sum_{i=1}^N \sum_{j=1}^N (\pi_{ij} - \pi_i \pi_j) \left(\frac{y_i}{\pi_i} \right)^2 - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\pi_{ij} - \pi_i \pi_j) \left(\frac{y_i}{\pi_i} - \frac{y_j}{\pi_j} \right)^2 \\ &= -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\pi_{ij} - \pi_i \pi_j) \left(\frac{y_i}{\pi_i} - \frac{y_j}{\pi_j} \right)^2 \end{aligned}$$

이다. 이때 마지막 등식은 고정표본수 추출에서

$$\begin{aligned} \sum_{i=1}^N \sum_{j=1}^N (\pi_{ij} - \pi_i \pi_j) \left(\frac{y_i}{\pi_i} \right)^2 &= \sum_{i=1}^N \left(\frac{y_i}{\pi_i} \right)^2 \sum_{j=1}^N (\pi_{ij} - \pi_i \pi_j) \\ &= \sum_{i=1}^N \left(\frac{y_i}{\pi_i} \right)^2 \left(\sum_{j=1}^N \pi_{ij} - \pi_i \sum_{j=1}^N \pi_j \right) \\ &= \sum_{i=1}^N \left(\frac{y_i}{\pi_i} \right)^2 (n\pi_i - n\pi_i) = 0 \end{aligned}$$

임에 따라 성립한다. □

Note 1. 한편 위로부터 $\pi_i \propto y_i$ 인 표본설계가 분산을 최소화함을 알 수 있다.

Theorem 3. 가측표본추출 하에서 분산 $\mathbb{V}(\hat{Y}_{HT})$ 에 대한 비편향추정량은

$$\hat{\mathbb{V}}(\hat{Y}_{HT}) = \sum_{i \in A} \sum_{j \in A} \frac{\pi_{ij} - \pi_i \pi_j}{\pi_{ij}} \frac{y_i y_j}{\pi_i \pi_j}$$

이며, 고정표본수 추출의 경우 SYG 공식을 이용하여

$$\hat{\mathbb{V}}(\hat{Y}_{HT}) = -\frac{1}{2} \sum_{i \in A} \sum_{j \in A} \frac{\pi_{ij} - \pi_i \pi_j}{\pi_{ij}} \left(\frac{y_i}{\pi_i} - \frac{y_j}{\pi_j} \right)^2$$

으로 추정할 수 있다.

Note 2. 일반적으로 HT 추정량은 적절한 조건에서 일치성과 근사적 정규성을 만족한다.

Note 3. 모평균을 추정하고자 하는 경우, \hat{Y}_{HT} 를 N 으로 나눈 값을 추정량으로 사용할 수 있다.

Note 4. HT 추정량은 location-scale invariant하지 않다. 즉 $z_i = a + by_i$ 를 정의하는 경우,

$$\hat{Z}_{HT} \neq aN + b\hat{Y}_{HT}$$

이 성립하지 않는다.

Note 5. 모집단 총계 $Y = \sum_{i=1}^N y_i$ 를

$$\hat{Y} = \sum_{i \in A} w_i y_i + C$$

처럼 추정하는 경우, $C = 0$ 이라면 \hat{Y} 가 불편추정량일 필요충분조건은 $w_i = 1/\pi_i$ 인 것이다.

Chapter 2

비복원 단순확률추출

2.1 비복원 단순확률추출

Definition 5. 크기가 N 인 유한모집단으로부터 n 개의 표본을 뽑을 때, 총 $\binom{N}{n}$ 개의 경우의 수가 존재한다. 이들에 동등한 확률을 주어

$$P(A) = \begin{cases} \binom{N}{n}^{-1} & \text{if } |A| = n \\ 0 & \text{o.w.} \end{cases}$$

를 표본분포로 하는 추출법을 비복원 단순확률추출(SRS)라 한다.

Theorem 4. 비복원 단순확률추출의 일차 표본포함확률과 이차 표본포함확률은

$$\pi_i = \frac{n}{N}$$
$$\pi_{ij} = \begin{cases} \frac{n}{N} & \text{if } i = j \\ \frac{n(n-1)}{N(N-1)} & \text{if } i \neq j \end{cases}$$

으로 주어진다.

Theorem 5. 비복원 단순확률추출의 HT 추정량은

$$\hat{Y}_{SRS} = \frac{N}{n} \sum_{i \in A} y_i = N\bar{y}$$

이다.

Theorem 6. 비복원 단순확률추출에서 분산의 추정값은

$$\hat{V}(\hat{Y}_{SRS}) = N^2 \times \frac{1}{n} \left(1 - \frac{n}{N}\right) s^2$$

으로 주어진다.

2.2 표본수의 결정

Definition 6. 유의수준 α 에서 오차한계 d 는

$$P(|\hat{\theta} - \theta| \leq d) = 1 - \alpha$$

를 만족하게 하는 값을 의미한다.

Theorem 7. 비복원 단순확률추출 하에서 모평균의 오차한계 d 는 근사적으로

$$d = z_{\alpha/2} \sqrt{\left(1 - \frac{n}{N}\right) \frac{\sigma^2}{n}}$$

으로 주어진다.

Theorem 8. 정해진 유의수준 α 와 오차한계 d 에 대하여, 필요한 표본의 크기는

$$n = \frac{\sigma^2}{(d/z_{\alpha/2})^2 + \sigma^2/N} = \frac{\frac{1}{d^2} z_{\alpha/2}^2 \sigma^2}{1 + \frac{1}{N} \frac{1}{d^2} z_{\alpha/2}^2 \sigma^2} \leq \frac{1}{d^2} z_{\alpha/2}^2 \sigma^2$$

이다. 즉 복원추출을 할 때의 표본크기 $\frac{1}{d^2} z_{\alpha/2}^2 \sigma^2$ 보다 더 적은 표본이 필요하다.

Note 6. 표본크기를 결정하기 위해서는 σ^2 를 알아야 하는데, 일반적으로는 이를 모른다. 표본분산을 이용하거나, 다양한 비모수적 방법들을 사용할 수 있다. 모비율 추정의 경우 $\sigma^2 = p(1-p) \leq 0.25$ 이기에, 이를 이용할 수도 있다.

Chapter 3

층화추출

3.1 층화추출

Definition 7. 모집단 U 를 서로 겹치지 않고 모집단을 전부 포함하는 H 개의 부차 모집단, 혹은 층 U_1, U_2, \dots, U_H 로 나눌 때, 각 층화된 모집단 U_h 내에서 층별 표본 A_h 를 독립적으로 추출하는 방법을 **층화추출**이라고 한다. 비복원 단순확률추출을 하는 경우 특정 부분에 표본이 몰릴 위험이 크지만, 층화추출을 하는 경우 이러한 위험에서 벗어날 수 있다.

Definition 8. 층 h 내에서의 i 번째 원소의 관심변수 y 의 값을 y_{hi} 라고 하면, 층 h 내에서의 y 의 총계는 $Y_h = \sum_{i=1}^{N_h} y_{hi}$ 로 표현되고 $Y = \sum_{h=1}^H Y_h$ 이다. 이때

$$\hat{Y}_{st} = \sum_{h=1}^H \hat{Y}_{HT,h}$$
$$\mathbb{V}(\hat{Y}_{st}) = \sum_{h=1}^H \mathbb{V}(\hat{Y}_{HT,h})$$

이다. 즉 각 층 내에서 추론을 수행한 뒤 이들을 단순히 합하여 추정량과 그들의 분산을 구할 수 있다.

Theorem 9. 만약 층 내에서 비복원 단순확률추출을 한다면,

$$\hat{Y}_{st} = \sum_{h=1}^H \frac{N_h}{n_h} \sum_{i \in A_h} y_{hi} = \sum_{h=1}^H N_h \bar{y}_h$$

이다. 그 분산추정량은

$$\hat{\mathbb{V}}(\hat{Y}_{st}) = \sum_{h=1}^H \mathbb{V}(\hat{Y}_{HT,h}) = \sum_{h=1}^H N_h^2 \left(1 - \frac{n_h}{N_h}\right) \frac{s_h^2}{n_h}$$

이다. 모평균에 대해 논의하고자 하는 경우, 추정량을 $N = N_1 + N_2 + \dots + N_H$ 으로 나누면 된다.

3.2 층화추출의 표본배정

전체 표본 크기 n 이 주어진 경우, 각 층에 표본수 n_h 를 배정할지에 대해 논의한다.

3.2.1 비례배정

Definition 9. 만약 $n_h = N_h \frac{n}{N}$ 이라면, **비례배정**이라 한다.

Theorem 10. 만약 비례배정을 통해 추정량을 얻은 경우, 분산추정량은

$$\hat{V}(\hat{Y}_{st}) = \frac{N^2}{n} \left(1 - \frac{n}{N}\right) \sum_{h=1}^H \frac{N_h}{N} s_h^2$$

이다.

Theorem 11. 각 층내에서 N_h 가 충분히 크다면,

$$\begin{aligned} \mathbb{V}(\hat{Y}_{st}) &= \frac{N^2}{n} \left(1 - \frac{n}{N}\right) \sum_{h=1}^H \frac{N_h}{N} \sigma_h^2 \\ &= \frac{N^2}{n} \left(1 - \frac{n}{N}\right) \frac{1}{N} \sum_{h=1}^H \frac{N_h}{N_h - 1} \sum_{i=1}^{N_h} (y_{hi} - \bar{Y}_h)^2 \\ &\approx \frac{N^2}{n} \left(1 - \frac{n}{N}\right) \frac{1}{N-1} \sum_{h=1}^H \sum_{i=1}^{N_h} (y_{hi} - \bar{Y}_h)^2 \\ &= \frac{N^2}{n} \left(1 - \frac{n}{N}\right) \frac{SSW}{N-1} \leq \frac{N^2}{n} \left(1 - \frac{n}{N}\right) \frac{SST}{N-1} = \frac{N^2}{n} \left(1 - \frac{n}{N}\right) \sigma^2 \end{aligned}$$

이 성립한다. 이때 SSW 는 층내 분산을 의미한다. 따라서 비례배정의 경우 층화추출이 거의 대부분 단순임의추출보다 더 효율적이다.

Note 7.

$$\underbrace{\sum_{h=1}^H \sum_{i=1}^{N_h} (y_{hi} - \bar{Y})^2}_{SST} = \underbrace{\sum_{h=1}^H N_h (\bar{Y}_h - \bar{Y})^2}_{SSB} + \underbrace{\sum_{h=1}^H \sum_{i=1}^{N_h} (y_{hi} - \bar{Y}_h)^2}_{SSW}$$

Note 8. 이로부터 층화추출은 층내원소들은 동질적이고, 층간은 이질적이어야 층화추출의 효율이 좋아짐을 알 수 있다. 단, 비례배정이 아닌 경우 이는 달라질 수 있다.

3.2.2 최적배정

Definition 10. 최적배정은 주어진 비용 하에서 HT 추정량의 분산을 최소화하는 배정을 의미한다. 이는 아래 최적화 문제의 해가 되는 n_h 를 결정하는 것과 같다.

$$\begin{cases} \text{minimize} & \mathbb{V}(\hat{Y}_{st}) = \sum_{h=1}^H N_h^2 \left(1 - \frac{n_h}{N_h}\right) \frac{\sigma_h^2}{n_h} \\ \text{subject to} & c_0 + \sum_{h=1}^H c_h n_h \leq C \\ & \sum_{h=1}^H n_h = n \end{cases}$$

Theorem 12. 최적배정의 결과, 최적표본수 n_h^* 는 $n_h^* \propto N_h \sigma_h / \sqrt{c_h}$ 으로 표현된다.

Proof. (n_1, \dots, n_H) 에 대한 라그랑주 승수법을 이용한다. 라그랑지안 \mathcal{L} 을 라그랑지안 승수 λ 에 대하여

$$\mathcal{L} = \sum_{h=1}^H N_h^2 \left(1 - \frac{n_h}{N_h}\right) \frac{\sigma_h^2}{n_h} - (C - c_0 - \sum_{h=1}^H c_h n_h)$$

로 정의하면,

$$\frac{\partial \mathcal{L}}{\partial n_h} = -\frac{N_h^2 \sigma_h^2}{n_h^2} + c_h = 0$$

에서 최적배정을 찾을 수 있다. 따라서

$$n_h \propto \frac{N_h \sigma_h}{\sqrt{c_h}}$$

□

Note 9. 만약 모든 c_h 가 상수 c 라면, 이를 **네이만 배정**이라 한다.

Note 10. 만약 모든 c_h 가 상수이고 층내 분산 σ_h 역시 상수라면, 이는 비례배정과 동일하다.

Note 11. 만약 두 층 간의 모평균 차이를 확인하고자 하는 경우, 최적배정은 $n_h^* \propto \sigma_h/\sqrt{c_h}$ 이다. 만약 σ_h 와 c_h 가 상수라면, 동등배정과 동일하다.

Note 12. 전체 모평균의 추정에는 N_h 에 비례하게 n_h 를 설정해야 하고, 차이 추정에는 이것이 포함되지 않는다. 이에 대한 절충으로 $0 < \alpha < 1$ 에 대하여 N_h^α 에 비례하는 배정을 수행할 수 있다. 이를 **떡배정**이라 한다.

Note 13. 층화추출에서, 오차한계를 d 로 하는 최소의 n 은

$$n = \frac{\sum_{h=1}^H \left(\frac{N_h}{N}\right)^2 \sigma_h^2 / w_h}{(d/z_{\alpha/2})^2 + \sum_{h=1}^H \frac{N_h}{N} \sigma_h^2 / N}$$

를 만족하게 결정한다. 이때 $w_h = n_h/n$ 이다.

만약 최적배정을 하는 경우,

$$n = \frac{(\sum_{h=1}^H N_h \sigma_h / \sqrt{c_h})(\sum_{h=1}^H N_h \sigma_h \sqrt{c_h})}{N^2 (d/z_{\alpha/2})^2 + \sum_{h=1}^H N_h \sigma_h^2}$$

이다.

3.3 사후층화

Definition 11. 층의 모비율 N_h/N 을 안다고 가정할 때, 먼저 비복원 단순확률추출을 통해 층화변수 Z_i 와 관심변수 y_i 를 얻었다고 가정하자. 이때 층화변수 Z_i 를 기준으로 H 개의 층으로 사후적으로 층화하여 추론하는 방법을 **사후층화**라고 한다.

Theorem 13. 사후층화를 하는 경우, 총계의 추정량은

$$\hat{Y}_{\text{post}} = \sum_{h=1}^H N_h \bar{y}_h$$

이다. 이때 \bar{y}_h 를 계산할 때의 표본수 n_h 가 확률변수라는 점이 일반적인 층화추출과 다르다.

Theorem 14. 사후층화로 얻은 추정량의 분산추정량은

$$\hat{V}(\hat{Y}_{\text{post}}) = \frac{N^2}{n} \left(1 - \frac{n}{N}\right) \sum_{h=1}^H \frac{N_h}{N} s_h^2 + \frac{N^2}{n^2} \sum_{h=1}^H \left(1 - \frac{N_h}{N}\right) s_h^2$$

으로 주어진다. 만약 n 이 크다면, 이는 비례배정에서와 거의 같아짐을 확인할 수 있다.

3.4 층화를 위한 이중표집

Definition 12. 만약 N_h/N 을 모르는 경우, 두 phase로 나누어 층화추출을 할 수 있다.

Phase 1: 큰 규모의 크기 n' 인 sample을 표집하고, $a'_h = n'_h/n'$ 을 계산하여 N_h/N 의 추정량으로 이용.

Phase 2: 작은 규모의 크기 n 인 sample을, n'_h 명 중 n_h 명을 표집함으로써 만든다.

Theorem 15. 모평균에 대한 추정량은

$$\bar{y}_{tp} = \sum_{h=1}^H a'_h \bar{y}_h$$

으로 주어진다. 만약 N 을 안다면, 여기에 N 을 곱하여 총계에 대한 추정량 역시 얻을 수 있다.

Theorem 16. 만약 n_h/N_h 가 충분히 작고 N 이 충분히 크며, n' 이 커 a'_h/n' 이 무시할 만하다면, 추정량의 분산은

$$\hat{V}(\bar{y}_{tp}) = \sum_{h=1}^H \left(\frac{a'^2_h s^2_h}{n_h} + \frac{a'_h (\bar{y}_h - \bar{y}_{tp})^2}{n'} \right)$$

으로 추정할 수 있다.

3.5 부차모집단에서의 비교

Definition 13. 특정한 부차모집단에 대한 지시변수가 δ_i 일 때, 해당 부차모집단에 대한 모평균의 비추정량은

$$\hat{\theta}_d = \frac{\sum_{i=1}^n \delta_i y_i / \pi_i}{\sum_{i=1}^n \delta_i / \pi_i}$$

로 주어진다.

Definition 14. 크기 N 인 모집단에 크기가 N_1, N_2 인 층(부차모집단)이 있다고 하자. N 에서 n 개의 SRS를 얻었고, 각각 n_1 개와 n_2 개의 개체를 표집하였다.

$$\hat{\Delta} = \hat{\mu}_1 - \hat{\mu}_2$$

라고 할 때, Δ 의 보수적인 분산추정량은

$$\hat{V}(\hat{\Delta}) \approx \left(1 - \frac{n}{N}\right) \left(\frac{s^2_1}{n_1} + \frac{s^2_2}{n_2}\right)$$

이다.

Chapter 4

일단계 집락추출

4.1 집락 크기가 같은 경우의 일단계 집락추출

Definition 15. 모집단이 N_I 개의 집락들로 구분되어 $U_I = \{1, 2, \dots, N_I\}$ 로 쓸 수 있다. U_i 는 크기 M_i 인 i 번째 집락이다. y_{ij} 를 i 번째 집락에서 j 번째 원소의 관심변수 값이라 하고

$$Y_i = \sum_{j \in U_i} y_{ij}, \bar{y}_i = \frac{Y_i}{M_i}$$

라고 두자. 일단계 집락추출에서는 U_I 로부터 집락들이 표본추출단위인 표본 A_I 를 추출하고 $n_I = |A_I|$ 개의 집락을 이용해 추론을 진행한다.

Definition 16. 모든 집락의 크기가 일정해 $M_i = M$ 인 경우, 비복원 단순확률추출을 통해 N_I 개의 집락 중 n_I 개의 집락을 뽑아 선택된 집락의 모든 원소들을 관측하는 상황을 고려하자. 이때 모집단 총계 $Y = \sum_{i=1}^{N_I} Y_i$ 에 대한 추정량은

$$\hat{Y}_{cl} = \frac{N_I}{n_I} \sum_{i \in A_I} Y_i$$

Definition 17. 모집단 평균을 추정하고자 하는 경우,

$$\bar{y}_{cl} = \frac{\hat{Y}_{cl}}{N_I M} = \frac{1}{n_I} \sum_{i \in A_I} \bar{y}_i$$

이다.

Theorem 17. 모집단 평균의 분산은

$$\mathbb{V}(\bar{y}_{cl}) = \frac{1}{n_I} \left(1 - \frac{n_I}{N_I}\right) \frac{1}{N_I - 1} \sum_{i=1}^{N_I} (\bar{y}_i - \bar{y}_{cl})^2 = \frac{1}{n_I} \left(1 - \frac{n_I}{N_I}\right) \frac{1}{N_I - 1} \frac{SSB}{M} = \frac{1}{n_I M} \left(1 - \frac{n_I}{N_I}\right) \sigma_b^2$$

으로 주어진다. 여기에서 SSB 는 집락간 변동제곱합, σ_b^2 은 $SSB/(N_I - 1)$ 이다.

Definition 18. 급내상관계수는 각 집락 내에서 원소들의 상관관계를 의미한다.

$$\rho = \frac{\text{Cov}(y_{ij}, y_{ik} | j \neq k)}{\sqrt{\mathbb{V}(y_{ij})} \sqrt{\mathbb{V}(y_{ik})}} = \frac{1}{M-1} \frac{\sum_{i=1}^{N_I} \sum_{j \neq k} (y_{ij} - \bar{y}_{cl})(y_{ik} - \bar{y}_{cl})}{\sum_{i=1}^{N_I} \sum_{j=1}^M (y_{ij} - \bar{y}_{cl})^2} = 1 - \frac{M}{M-1} \frac{SSW}{SST}$$

이다. 이때 SST 는 총변동제곱합, SSW 는 집락내 변동제곱합이다.

Theorem 18. 급내상관계수는

$$-\frac{1}{M-1} \leq \rho \leq 1$$

의 범위를 가지며, 최소값을 가지는 경우는 $SSB = 0$ 으로 집락내 평균 \bar{y}_i 가 모두 동일한 경우이다. 반대로 최대값을 가지는 경우는 $SSW = 0$ 으로 집락 내의 모든 원소들이 동일한 경우이다.

Theorem 19. N_I 가 충분히 큰 경우에,

$$\mathbb{V}(\hat{Y}_{cl}) \approx \mathbb{V}(\hat{Y}_{SRS}) \times (1 + (M-1)\rho)$$

이다.

Proof. $SST = SSB + SSW$ 이므로,

$$SSB = \frac{1}{M}(1 + (M-1)\rho)SST$$

가 성립한다. 이때

$$\begin{aligned} \mathbb{V}(\hat{Y}_{cl}) &= \frac{1}{n_I} \left(1 - \frac{n_I}{N_I}\right) \frac{1}{N_I-1} \frac{SSB}{M} \\ &= \frac{1}{n_I} \left(1 - \frac{n_I}{N_I}\right) \frac{1}{N_I-1} \frac{(1 + (M-1)\rho)SST}{M^2} \\ &= \frac{1}{n_I M} \left(1 - \frac{n_I}{N_I}\right) \frac{SST}{N_I M - 1} (1 + (M-1)\rho) \times \frac{N_I M - 1}{(N_I - 1)M} \\ &\approx \frac{1}{n_I M} \left(1 - \frac{n_I}{N_I}\right) \sigma^2 \times (1 + (M-1)\rho) \\ &= \mathbb{V}(\hat{Y}_{SRS}) \times (1 + (M-1)\rho) \end{aligned}$$

□

4.2 표본설계효과

Definition 19. 표본설계효과는 특정 표본설계 하에서의 분산을 같은 표본수의 비복원 단순확률추출에서의 분산으로 나눈 값, 즉

$$\text{deff}(\hat{Y}_p, \hat{Y}_{SRS}) = \frac{\mathbb{V}(\hat{Y}_p)}{\mathbb{V}(\hat{Y}_{SRS})}$$

으로 정의된다. 집락 크기가 같은 일단계 집락추출의 경우, 표본설계효과는 $1 + (M-1)\rho$ 이다.

Note 14. 만약 ρ 가 음수이면, 즉 집락내의 원소의 성질이 이질적이면, 집락추출이 단순임의추출보다 효율적이다. 그렇지 않은 대부분의 경우에는 추정의 효율이 SRS에 비해 비효율적이다.

Definition 20. 유효표본수는 특정 표본추출방법에서의 총 표본수가 n 일 때, 동일한 효과를 내기 위해 SRS에서 몇 개의 표본이 필요한지를 의미한다.

Note 15. 집락추출에서 유효표본수를 n^* 이라고 하면,

$$\frac{1}{n_I M} \left(1 - \frac{n_I}{N_I}\right) \sigma^2 \times (1 + (M-1)\rho) = \frac{1}{n^*} \left(1 - \frac{n^*}{N_I M}\right) \sigma^2$$

이 만족해야 하기에

$$n^* = \frac{n_I M}{1 + (M-1)\rho}$$

로 주어진다.

4.3 집락 크기가 다른 경우의 일단계 집락추출

Definition 21. 집락의 크기 M_i 가 다른 경우, 모든 집락의 추출확률을 동일하게 하는 것은 최적일 수 있다. 각 집락의 일차표본포함확률을 $\pi_{Ii} = P(i \in A_I)$ 라 할 때, 모집단 총계의 추정량은

$$\hat{Y}_{cl} = \sum_{i \in A_I} \frac{Y_i}{\pi_{Ii}}$$

이다.

Theorem 20. 고정표본수 집락추출의 경우, 위 추정량의 분산은

$$\mathbb{V}(\hat{Y}_{cl}) = -\frac{1}{2} \sum_{i=1}^{N_I} \sum_{j=1}^{N_I} (\pi_{Iij} - \pi_{Ii}\pi_{Ij}) \left(\frac{Y_i}{\pi_{Ii}} - \frac{Y_j}{\pi_{Ij}} \right)^2$$

이다.

Definition 22. M_i 가 서로 다름에도 이를 무시하고 집락 모집단에서 비복원 단순확률추출을 사용하여 집락을 뽑는 방법을 **단순확률 집락추출**이라 한다. 이때 총계의 추정량은

$$\hat{Y}_{SRC} = \frac{N_I}{n_I} \sum_{i \in A_I} Y_i$$

이며, 그 분산은

$$\mathbb{V}(\hat{Y}_{SRC}) = \frac{N_I^2}{n_I} \left(1 - \frac{n_I}{N_I} \right) \sigma_I^2$$

이다. 이때 σ_I 는 Y_i 들의 분산이다.

Definition 23. 집락크기 M_i 가 다른 경우, **급락 동질성 계수**를 아래처럼 정의할 수 있다.

$$\delta = 1 - \frac{\sum_{i \in U_I} \sum_{j \in U_i} (y_{ij} - \bar{y}_i)^2 / (N - N_I)}{\sum_{i \in U_I} \sum_{j \in U_i} (y_{ij} - \bar{y}_{SRC})^2 / (N - 1)} = 1 - \frac{SSW / (N - N_I)}{SST / (N - 1)}$$

이때 $\bar{y}_{SRC} = \bar{Y}$ 이다. 만약 집락크기가 모두 동일한 경우, δ 는 급내상관계수와 동일하다.

Theorem 21.

$$K_I = \frac{N_I^2}{n_I} \left(1 - \frac{n_I}{N_I} \right), \quad C^* = \frac{1}{N_I - 1} \sum_{i=1}^{N_I} (M_i - \bar{M}) M_i \bar{y}_i^2$$

을 정의하면

$$\mathbb{V}(\hat{Y}_{SRC}) = \left(1 + \frac{N - N_I}{N_I - 1} \delta \right) \bar{M} \sigma^2 K_I + C^* K_I$$

이며

$$\mathbb{V}(\hat{Y}_{SRS}) = \bar{M} \sigma_y^2 K_I$$

로 표현할 수 있으므로, 표본설계효과는

$$\text{deff}(SRC, SRS) = \left(1 + \frac{N - N_I}{N_I - 1} \delta \right) + \frac{C^*}{\bar{M} \sigma_y^2}$$

이다. 따라서 $\delta > 0$ 이여 집락 내가 동질적이거나, $C^* > 0$ 이여 집락크기가 다르다면 추정의 효율이 감소하게 된다.

4.4 평균 추정

Definition 24. SRC에서 얻는 평균의 추정량은

$$\bar{y}_{SRC} = \frac{\sum_{i \in A_I} M_i Y_i}{\sum_{i \in A_I} M_i}$$

이다.

Theorem 22. SRC에서 얻는 평균추정량의 추정분산은

$$\hat{V}(\bar{y}_{SRC}) = \frac{1}{n_I M^2} \left(1 - \frac{n_I}{N_I}\right) \frac{1}{n_I - 1} \sum_{i \in A_I} M_i^2 (\bar{y}_i - \bar{y}_{SRC})^2$$

이다.

4.5 총계 추정과 표본 크기의 선택

Theorem 23. 만약 전체 개체수 M 을 알면, τ_y 는 $M\bar{y}_{SRC}$ 로 추정하며, 그 분산은

$$\hat{V}(M\bar{y}_{SRC}) = N_I^2 \left(1 - \frac{n_I}{N_I}\right) \frac{s_r^2}{n_I}$$

이다. 반면 개체수를 모르면, τ_y 는

$$N_I \bar{y}_t = \frac{N}{n} \sum_{i=1}^n y_i$$

으로 추정하며, 그 분산은

$$\hat{V}(N_I \bar{y}_t) = N_I^2 \left(1 - \frac{n_I}{N_I}\right) \frac{s_t^2}{n_I}$$

으로 추정한다. s_t^2 는 y_i 의 분산이다.

Theorem 24. \bar{y}_{SRC} 를 오차한계 B 로 추정하려 한다면, 필요한 집락표본수는

$$n^* = \frac{N_I^2 s_r^2}{N_I^2 \left(\frac{B\bar{M}}{2}\right)^2 + N_I s_r^2}$$

이다.

Theorem 25. 총계를 추정하려 하는 경우, M 을 안다면 오차한계 B 로 할 때

$$n^* = \frac{N_I^2 s_r^2}{N_I^2 \left(\frac{B}{2N_I}\right)^2 + N_I s_r^2}$$

이며, M 을 모른다면

$$n^* = \frac{N_I^2 s_t^2}{N_I^2 \left(\frac{B}{2N_I}\right)^2 + N_I s_t^2}$$

이다.

Chapter 5

이단계 집락추출

Definition 25. 이단계 집락추출에서는 첫 번째 추출에서는 집락이 추출되고 두 번째 추출에서는 일단계에서 표본으로 추출된 집락으로부터 원소를 추출하는 방법을 의미한다. 이단계 집락추출에서는 집락 i 의 모든 원소를 관측하지 못하므로 Y_i 는 알지 못하며, 부차표본추출을 통하여 그 추정치 \hat{Y}_i 를 얻고 이를 이용한다.

Definition 26. 모집단 총계 Y 의 비편향추정량은

$$\hat{Y}_{2cl} = \sum_{i \in A_I} \frac{\hat{Y}_i}{\pi_{Ii}} = \sum_{i \in A_I} \sum_{k \in A_i} \frac{y_{ik}}{\pi_{k|i} \pi_{Ii}}$$

으로 표현되고 $\pi_{Ii} = P(i \in A_I), \pi_{k|i} = P(k \in U_i)$ 이다.

Theorem 26. \hat{Y}_{2cl} 의 분산은

$$\mathbb{V}(\hat{Y}_{2cl}) = \underbrace{\mathbb{V}(\mathbb{E}[\hat{Y}_{2cl}|A_I])}_{V_{PSU}} + \underbrace{\mathbb{E}[\mathbb{V}(\hat{Y}_{2cl}|A_I)]}_{V_{SSU}}$$

로 각 표본추출단위를 추출함으로써 발생하는 분산의 합으로 표현할 수 있다. 이때

$$V_{PSU} = \sum_{i \in U_I} \sum_{j \in U_I} (\pi_{Iij} - \pi_{Ii} \pi_{Ij}) \frac{Y_i}{\pi_{Ii}} \frac{Y_j}{\pi_{Ij}}$$

$$V_{SSU} = \sum_{i \in U_I} \frac{V_i}{\pi_{Ii}} = \sum_{i \in U_I} \frac{1}{\pi_{Ii}} \sum_{k \in U_i} \sum_{l \in U_i} (\pi_{kl|i} - \pi_{k|i} \pi_{l|i}) \frac{y_{ik}}{\pi_{k|i}} \frac{y_{il}}{\pi_{l|i}}$$

이다.

Theorem 27. 아래와 같은 이단계 집락추출을 생각한다.

1. 제 1단계 추출: N_I 개의 집락으로부터 n_I 개의 표본집락을 SRS로 추출
2. 제 2단계 추출: 각 표본집락 i 내의 M_i 개의 원소로부터 m_i 개의 원소를 SRS로 추출

이때

$$\hat{Y}_{2cl} = \frac{N_I}{n_I} \sum_{i \in A_I} \hat{Y}_i = \sum_{i \in A_I} \sum_{j \in A_i} \frac{N_I}{n_I} \frac{M_i}{m_i} y_{ij}$$

이며, 그 분산은

$$\mathbb{V}(\hat{Y}_{2cl}) = N_I^2 \left(1 - \frac{n_I}{N_I}\right) \frac{\sigma_I^2}{n_I} + \left(\frac{N_I}{n_I}\right) \sum_{i=1}^{N_I} M_i^2 \left(1 - \frac{m_i}{M_i}\right) \frac{\sigma_{2i}^2}{m_i}$$

이다. 이때 σ_{2i}^2 은 i 번째 집락에서의 분산이다.

Theorem 28. 이단계 집락추출에서 분산의 추정량은

$$\hat{V}(\hat{Y}_{2cl}) = \sum_{i \in A_I} \sum_{j \in A_I} \frac{\pi_{Iij} - \pi_{Ii}\pi_{Ij}}{\pi_{Iij}} \frac{\hat{Y}_i}{\pi_{Ii}} \frac{\hat{Y}_j}{\pi_{Ij}} + \sum_{i \in A_I} \frac{1}{\pi_{Ii}} \hat{V}_i$$

이다. 이단계 집락추출을 **Theorem 24**와 동일한 방식으로 수행하는 경우,

$$\hat{V}(\hat{Y}_{2cl}) = N_I^2 \left(1 - \frac{n_I}{N_I}\right) \frac{s_I^2}{n_I} + \left(\frac{N_I}{n_I}\right) \sum_{i=1}^{N_I} M_i^2 \left(1 - \frac{m_i}{M_i}\right) \frac{s_{2i}^2}{m_i}$$

을 얻는다.

Theorem 29. 이단계 집락추출의 표본설계 효과는 n_I/N_I 가 충분히 작을 때

$$\text{deff} = k(1 + (\bar{m} - 1)\delta)$$

이다. 이때 k 는

$$k = \frac{(1 + (\bar{M} - 1)\delta)\sigma_y^2 + C^*/\bar{M}}{(1 + (\bar{M} - 1)\delta)\sigma_y^2}$$

이다.

Theorem 30. 만약 $M_1 = M_2 = \dots = M_N = \bar{M}$, $m_1 = m_2 = \dots = m_n = m$ 이라면,

$$\hat{\mu} = \frac{1}{nm} \sum_{i=1}^n \sum_{j=1}^m y_{ij}$$

이며,

$$\hat{V}(\hat{\mu}) = \left(1 - \frac{n}{N}\right) \frac{MSB}{nm} + \left(1 - \frac{m}{M}\right) \frac{MSW}{Nm}$$

이 된다. 또한

$$MSB = \frac{1}{n-1} \sum_{i=1}^n \sum_{j=1}^m (\bar{y}_i - \hat{\mu})^2, \quad MSW = \frac{1}{n(m-1)} \sum_{i=1}^n \sum_{j=1}^m (y_{ij} - \bar{y}_i)^2$$

Theorem 31. 표집에 필요한 총비용이

$$c = nc_1 + nmc_2$$

일 때,

$$m = \sqrt{\frac{\sigma_w^2 c_1}{\sigma_b^2 c_2}}$$

이면 분산이 최소화된다. 이후

$$V(\hat{\mu}) = \frac{1}{n} \left(\sigma_b^2 + \frac{\sigma_w^2}{m} \right)$$

를 이용하여 n 을 결정해주면 된다. 이때 σ_w^2 은 MSW 로, σ_b^2 은 $(MSB - MSW)/m$ 으로 추정한다.

Chapter 6

층화집락추출

Definition 27. 모집단을 여러 개의 층으로 나눈 후 각각의 층에서 집락추출을 수행하는 방법을 **층화집락추출**이라 한다. H 개의 층이 있고 각 층에 N_{Ih} 개의 집락이 있으며, 그 중 n_{Ih} 개의 집락을 추출하여 조사를 진행하였다고 하자.

이때 모평균의 추정량은

$$\bar{y}_c = \frac{\sum_{h=1}^H N_{Ih} \bar{Y}_{Ih}}{\sum_{h=1}^H N_{Ih} M_{Ih}}$$

이며, 그 분산추정량은

$$\hat{V}(\bar{y}_c) = \frac{1}{M^2} \sum_{h=1}^H N_h^2 \left(1 - \frac{n_h}{N_h}\right) \frac{s_{ch}^2}{n_h}$$

이다. 이때 M 은 총 원소수로 추정해야 하는 값이며, s_{ch}^2 은 h 번째 층에서 얻은 $Y_i - \bar{y}_c m_i$ 의 분산이다.

Chapter 7

비추정과 회귀추정

7.1 비추정

Definition 28. 모집단의 보조정보가 알려져 있는 경우, 보조변수 X 와 연구 대상인 Y 사이의 관계를 파악하여 이 관계를 Y 의 모수 추정에 이용할 수 있다. 대표적으로,

$$\sum_{i=1}^N y_i = \beta \sum_{i=1}^N x_i$$

가 만족할 때 이들의 비 β 를 이용하는 **비추정법**을 사용할 수 있다.

Definition 29. 모비율 R 은 아래와 같이 정의된다.

$$R = \frac{\tau_y}{\tau_x} = \frac{\mu_x}{\mu_y}$$

이때 τ_x, τ_y 는 각각의 모합, μ_x, μ_y 는 각각의 모평균이다. 이때 모비율 R 의 추정량은

$$r = \frac{\sum_{i=1}^n y_i}{\sum_{i=1}^n x_i} = \frac{\bar{y}}{\bar{x}}$$

이며, 그 분산추정량은

$$\hat{V}(r) = \left(1 - \frac{n}{N}\right) \left(\frac{1}{\mu_x^2}\right) \frac{s_r^2}{n}$$

이다. 이때 s_r^2 은 $y_i - rx_i$ 의 표본분산

$$s_r^2 = \frac{\sum_{i=1}^n (y_i - rx_i)^2}{n-1}$$

이다.

Note 16. 만약 μ_x 를 모른다면 \bar{x} 로 대체할 수 있다.

Note 17. 모총계 τ_y 는

$$\hat{\tau}_y = r\hat{\tau}_x$$

으로 추정하며, 그 분산추정량은

$$\hat{V}(\hat{\tau}_y) = N^2 \left(1 - \frac{n}{N}\right) \frac{s_r^2}{n}$$

이다.

Note 18. 모평균 μ_y 는

$$\hat{\mu}_y = r\mu_x$$

으로 추정하며, 그 분산추정량은

$$\hat{V}(\hat{\mu}_y) = \frac{1}{N^2} \left(1 - \frac{n}{N}\right) \frac{s_r^2}{n}$$

이다.

Theorem 32. r 의 분산추정량은 $\hat{\rho} = \frac{s_{xy}}{s_x s_y}$ 를 이용하여

$$\hat{V}(r) = \left(1 - \frac{n}{N}\right) \left(\frac{1}{\mu_x^2}\right) \frac{1}{n} (s_y^2 + r^2 s_x^2 - 2r \hat{\rho} s_x s_y)$$

처럼 쓸 수도 있다.

7.1.1 비추정과 SRS의 비교

Theorem 33. 비추정에서, 오차한계 d 로 모비 β 를 추정하기 위한 표본크기는

$$n = \frac{N\sigma_r^2}{N(d\mu_x/z_{\alpha/2})^2 + \sigma_r^2}$$

으로 주어진다.

Theorem 34. 비추정에서, 오차한계 d 로 모합 τ_y 를 추정하기 위한 표본크기는

$$n = \frac{N\sigma_r^2}{N(d/Nz_{\alpha/2})^2 + \sigma_r^2}$$

으로 주어진다.

Theorem 35. 비추정에서, 오차한계 d 로 모평균 μ_y 를 추정하기 위한 표본크기는

$$n = \frac{N\sigma_r^2}{N(d/z_{\alpha/2})^2 + \sigma_r^2}$$

으로 주어진다.

Theorem 36. 비추정에서의 분산은

$$\mathbb{V}(\hat{\mu}_y) = \left(1 - \frac{n}{N}\right) \frac{\sigma_r^2}{n}$$

이며, SRS에서의 분산은

$$\mathbb{V}(\hat{\mu}_y) = \left(1 - \frac{n}{N}\right) \frac{\sigma_y^2}{n}$$

이다. 따라서 σ_r^2 와 σ_y^2 을 비교하여 둘의 효율을 비교할 수 있다. 이때 **Theorem 27**에서와 같이

$$\sigma_r^2 = \sigma_y^2 + r^2 \sigma_x^2 - 2r\rho\sigma_x\sigma_y$$

이므로, 상대효율성은

$$RE(SRC, SRS) = \frac{\mathbb{V}_{SRS}(\hat{\mu}_y)}{\mathbb{V}_{SRC}(\hat{\mu}_y)} = \left(1 + r^2 \frac{\sigma_x^2}{\sigma_y^2} - 2r\rho \frac{\sigma_x}{\sigma_y}\right)^{-1}$$

으로 주어지고, 비추정량이 더 효율적일 조건은 $\rho > \frac{1}{2}r \frac{\sigma_x}{\sigma_y}$, 혹은

$$\frac{1}{2} \frac{CV(x)}{CV(y)} < \text{corr}(x, y)$$

으로 쓸 수도 있다. 따라서 일반적으로 x 와 y 의 correlation이 강할수록 상대효율성이 좋아진다.

7.1.2 층화표집에서의 비추정량

Definition 30. 분리비추정량은 각 층의 추정량을 얻는 데 비추정량을 사용하는 방법이다. 각 층에서,

$$r_h = \frac{t_{yh}}{t_{xh}} = \frac{\bar{y}_h}{\bar{x}_h}$$

과 이를 통한

$$\hat{\tau}_{yh} = r_h \tau_{xh}$$

를 구하고, 이를 통해 모함 τ_y 에 대한 분리비추정량

$$\hat{\tau}_y = \sum_{h=1}^H \hat{\tau}_{yh} = \sum_{h=1}^H b_h \tau_{xh}$$

을 얻을 수 있다. 그 분산추정량은

$$\hat{V}(\hat{\tau}_y) = \sum_{h=1}^H N_h^2 \left(1 - \frac{n_h}{N_h}\right) \frac{s_{\tau h}^2}{n_h}$$

이다.

Theorem 37. 모평균 μ_y 에 대한 분리비추정량은

$$\hat{\mu}_y = \frac{1}{N} \hat{\tau}_y = \sum_{h=1}^H \frac{N_h}{N} b_h \mu_{xh}$$

이며, 그 분산추정량은

$$\hat{V}(\hat{\mu}_y) = \sum_{h=1}^H \left(\frac{N_h}{N}\right)^2 \left(1 - \frac{n_h}{N_h}\right) \frac{s_{\tau h}^2}{n_h}$$

이다.

Definition 31. 병합비추정량은 각 층의 정보를 모두 합친 뒤 비추정을 수행하는 방법으로,

$$r = \frac{\hat{\tau}_y}{\hat{\tau}_x} = \frac{\bar{y}_{st}}{\bar{x}_{st}}$$

이며 그 분산추정량은

$$\hat{V}(r) = \frac{1}{\mu_x^2} \sum_{h=1}^H \left(\frac{N_h}{N}\right)^2 \left(1 - \frac{n_h}{N_h}\right) \frac{s_{\tau h}^2}{n_h}$$

이다. 모함, 모평균에 대한 추정량은 각각 τ_x, μ_x 를 곱하여

$$\hat{\tau}_y = r \tau_x, \quad \hat{V}(\hat{\tau}_y) = \sum_{h=1}^H N_h^2 \left(1 - \frac{n_h}{N_h}\right) \frac{s_{\tau h}^2}{n_h}$$

$$\hat{\mu}_y = r \mu_x, \quad \hat{V}(\hat{\mu}_y) = \sum_{h=1}^H \left(\frac{N_h}{N}\right)^2 \left(1 - \frac{n_h}{N_h}\right) \frac{s_{\tau h}^2}{n_h}$$

으로 각각이 주어진다.

Note 19. 일반적으로 분리비추정량이 더 효율적이지만, 요구하는 정보와 표본크기가 많아 비용이 많이 든다. 둘은 $s_{\tau h}^2$ 의 계산에서 사용하는 비 r 이 층별비 r_h 와 전체비 r 이라는 점에서 다르다.

7.2 회귀추정

Definition 32. 모집단 $\{(x_i, y_i), i = 1, 2, \dots, N\}$ 에서 n 개의 표본을 얻는다. 변수 x_i 와 y_i 가 선형의 관계 $y = \alpha + \beta x$ 를 가지고 있다고 가정할 때, α 와 β 에 대한 최소제곱추정량은

$$\hat{\beta} = b = \frac{s_{XY}}{s_X^2} = \frac{rS_Y}{s_X}$$

$$\hat{\alpha} = a = \bar{Y} - b\bar{X}$$

이며, y 의 평균 μ_y 의 회귀 추정량은

$$\hat{\mu}_y = a + b\mu_x = \bar{Y} + b(\mu_x - \bar{X})$$

이다.

Theorem 38. 회귀추정량의 편의는

$$\text{bias}(\hat{\mu}_y) = \mathbb{E}[\hat{\mu}_y - \mu_y] = -\text{Cov}(b, \bar{X})$$

이며, 분산은

$$\hat{V} = \left(1 - \frac{n}{N}\right) \frac{MSE}{n}$$

으로 추정된다.

7.2.1 차이추정

Definition 33. μ_y 에 대한 차이추정량은

$$\hat{y} = \bar{y} + (\mu_x - \bar{x}) = \mu_x + (\bar{d})$$

로 주어진다. 그 분산추정량은

$$\hat{V}(\hat{\mu}) = \left(1 - \frac{n}{N}\right) \frac{s_d^2}{n}$$

이다. 이때 $d_i = y_i - x_i$, s_d^2 은 그 분산추정량이다.

Chapter 8

계통추출

8.1 계통추출

Definition 34. 단순확률추출을 할 때 표본을 뽑는 가장 간단한 방법은 표본추출틀 하에서 일정한 간격을 두고 표본을 선택하는 것이다. 이러한 추출방법을 **계통추출**이라 한다.

Note 20. 계통추출은 매우 간단하며, 전체 표집틀을 가지고 있지 않아도 되며, 비용이 적게 든다는 장점이 있다.

Definition 35. 처음 k 개 원소 중 하나를 임의로 고르고, 그 이후 k 개마다 원소를 추출해 얻은 표본을 1 in k 계통표본이라 부른다.

Note 21. 만약 전체 모집단의 원소 수를 안다면, 첫 원소를 $1/k$ 의 확률로 선택하는 대신 계통추출의 표본 수에 비례하게 표본추출을 수행하는 방법 역시 사용할 수 있다. 둘째 방법은 N 를 알 때만 사용할 수 있지만 불편추정량을 얻을 수 있는 반면, 첫째 방법은 N 을 모를 때도 사용할 수 있지만 약간의 편의를 가진다.

Theorem 39. 계통추출에서 모평균의 추정량은

$$\mathbb{E}[\bar{y}_{sy}] = \frac{\sum_{i=1}^n y_i}{n}$$

이며, 그 분산추정량은 단순확률추출에서와 같이

$$\hat{V}(\bar{y}_{sy}) = \left(1 - \frac{n}{N}\right) \frac{s^2}{n}$$

이다.

Note 22. 단, 추정 방법이 같다고 해서 실제 분산이 같다는 것은 아니다. 실제로는

$$V(\bar{y}_{sy}) = \frac{\sigma^2}{n}(1 + (n-1)\rho)$$

이며, 이때 ρ 는 급내상관계수이다. 따라서 급내상관계수가 작은 경우에 분산이 작으며, 그렇지 않은 경우 분산이 크다. 계통추출된 표본 내의 원소들이 동질적일 때보다는 이질적일 때 그 분산이 작아진다.

Definition 36. 모집단이 **랜덤모집단**이라는 것은 모집단의 원소들이 랜덤한 순서로 배치되어 있음을 의미한다.

모집단이 **순서모집단**이라는 것은 상승, 혹은 하락하는 순서로 배치된 모집단을 의미한다.

주기모집단은 모집단의 원소들이 일정한 주기성을 가지고 배치되어 있음을 의미한다.

Note 23. 만약 순서모집단일 경우 급내상관계수가 낮아 계통추출에서 얻는 추정량의 분산이 작다. 따라서 분산추정량은 실제 분산을 과대평가한다. 반면 주기모집단일 경우 급내상관계수가 커 계통추출에서 얻는 추정량의 분산이 크다. 따라서 분산추정량은 실제 분산을 과소평가한다.

Note 24. 모함, 모비율 등의 추정은 이를 통해 쉽게 수행할 수 있으며, 필요한 표본크기의 경우 SRS와 동일하다.

8.2 반복계통추출

Definition 37. 반복계통추출은 N 명의 모집단에서 n 명을 계통표집하는 대신, n' 명을 계통추출하는 것을 n_s 번 반복하여

$$(Y_{11}, Y_{12}, \dots, Y_{1n'}), (Y_{21}, Y_{22}, \dots, Y_{2n'}), \dots, (Y_{n_s,1}, Y_{n_s,2}, \dots, Y_{n_s,n'})$$

을 얻는 방법을 의미한다.

Definition 38. n_s 개의 표본평균 $\bar{y}_1, \bar{y}_2, \dots, \bar{y}_{n_s}$ 을 얻었다. 이때 평균 추정량은

$$\hat{\mu} = \frac{1}{n_s} \sum_{i=1}^{n_s} \bar{y}_i$$

이며, 그 분산추정량은

$$\hat{V}(\hat{\mu}) = \left(1 - \frac{n}{N}\right) \frac{s_y^2}{n_s}$$

이다. 이때 s_y^2 은 \bar{y}_i 의 분산추정량이다.

8.3 모형을 이용한 추정

Theorem 40. $N = nk$ 가 충분히 클 때,

$$\rho = \frac{(k-1)nMSB - SST}{(n-1)SST} \approx \frac{MSB - MST}{(n-1)MST}$$

이다. 이때

$$MSB = \frac{n}{k-1} \sum_{i=1}^k (\bar{y}_i - \bar{\bar{y}})^2, \quad MST = \frac{1}{nk-1} \sum_{i=1}^k \sum_{j=1}^n (y_{ij} - \bar{\bar{y}})^2$$

이다.

Theorem 41. 선형추세가 있는 자료에서는 아래를 분산추정량으로 사용할 수 있다.

$$\hat{V}(\bar{y}_{sy}) = \left(1 - \frac{n}{N}\right) \frac{1}{2n(n-1)} \sum_{i=1}^{n-1} d_i^2$$

이때 $d_i = y_{i+1} - y_i$ 이다.

Chapter 9

모집단 크기의 추정

9.1 포획-재포획 추정

Definition 39. 집단의 크기가 N 일 때, 해당 집단에 유입/유출이 없고 모든 개체가 포획될 확률이 동일하다고 하자. 그렇다면

1. t 개의 개체를 포획하고 표지를 붙인 후 방류
2. 일정 시간이 지난 후 n 개의 개체를 포획하고 표지가 있는 개체의 개수 s 을 확인

했을 때, N 의 추정량은

$$\hat{N} = \frac{nt}{s}$$

이며, 그 분산은

$$\hat{V}(\hat{N}) = \frac{t^2 n(n-s)}{s^3}$$

으로 추정된다.

Proof. \hat{N} 은 비추정량으로 표현할 수도 있다. 재포획 상황에서, i 번째 물고기에 표지가 달린지 여부를 x_i 로 표현하고, 모든 i 에 대해 $y_i = 1$ 이라 하자. 그렇다면

$$\tau_x = t, \quad \tau_y = N$$

이며 재포획으로부터 얻은 $\beta = \frac{\tau_y}{\tau_x}$ 의 비추정량은

$$b = \frac{n}{s}$$

이다. 따라서 비추정량으로 얻은 Y 의 추정량이 $\frac{nt}{s}$ 이다. 한편 그 분산은

$$\hat{V}(\hat{N}) = \hat{N}^2 \left(1 - \frac{n}{\hat{N}}\right) \frac{s_e^2}{n} = \frac{nt^2(t-s)}{s^2} = \hat{N}^2 \left(1 - \frac{n}{\hat{N}}\right) \frac{n(n-s)}{s(n-1)} \approx \frac{t^2 n(n-s)}{s^3}$$

으로 추정된다. □

Definition 40. 앞서 고정된 n 개의 개체를 포획하는 *direct sampling*과는 달리, *inverse sampling*에서는 재포획에서 s 마리의 꼬리표 달린 개체가 포획될 때까지 임의포집한다. 즉

$$n \sim NB\left(s, \frac{t}{N}\right)$$

이다. 이때 N 에 대한 비편향추정량은

$$\hat{N} = \frac{nt}{s}$$

이며, 그 추정분산은

$$\hat{V}(\hat{N}) = \frac{t^2 n(n-s)}{s^2(s+1)}$$

으로 *direct sampling*과 유사하다.

9.2 사각표집

Definition 41. 분할된 구획인 사각에서 밀도를 측정하고, 밀도와 총면적을 곱하여 개체의 총수를 추정하는 방법을 **사각표집**이라 한다. 총면적 A 의 영역을 면적 a 의 K 개 사각으로 나누는 뒤, k 개의 사각을 단순임의표집하여 개체수를 세면 i 번째 사각에서의 개체수 Y_i 이라 할 때 $Y_i \sim \text{Poisson}(\lambda a)$ 를 따른다. 이때 λ 는 단위 면적당 개체수를 의미한다.

Theorem 42. 면적당 개체수 λ 는

$$\hat{\lambda} = \frac{1}{a} \bar{Y} = \frac{1}{ak} \sum_{i=1}^k Y_i$$

으로 추정한다. 또한 전체 개체수 N 은

$$\hat{N} = \hat{\lambda} A$$

로 추정한다.

Theorem 43. \hat{N} 은 불편추정량이며, 그 분산추정량은

$$\hat{V}(\hat{N}) = A^2 \left(\frac{\hat{\lambda}}{ak} \right)$$

Definition 42. **적재사각표집**은 개체수를 정확히 세는 대신 존재여부만을 기록하는 사각표집 방법을 의미한다. 푸아송모형을 가정하면

$$Z_i = \begin{cases} 1 & I(Y_i \geq 1) \\ 0 & I(Y_i < 1) \end{cases}$$

이고, $P(Z_i = 1) = 1 - e^{-\lambda a}$ 이다. 그렇다면 $Z_i = 0$ 인 사각의 개수를 y 라 하면

$$\hat{\lambda} = -\frac{1}{a} \log \left(\frac{y}{k} \right)$$

이며,

$$\hat{M} = \hat{\lambda} A, \quad \hat{V}(\hat{M}) = \frac{A^2}{ka^2} (e^{\hat{\lambda} a} - 1)$$

9.3 임의화 반응

Definition 43. 민감한 질문을 해야 하는 경우, 전혀 무관한 무해한 질문을 동시에 하여 응답자로 하여금 임의선택된 질문에 대하여 답하도록 하는 절차이다. 예를 들어,

(질문 1) 뇌물을 받은 적이 있습니까?

(질문 2) 뇌물을 받은 적이 없습니까?

그 다음 카드 7장에는 질문 1을, 카드 3장에는 질문 2를 적어 통에 넣고 임의로 1장의 카드를 선택하여 예, 아니오의 답만 기록한다. 그렇다면 뇌물을 받은 비율을 p_s , 질문 1을 뽑은 비율을 π 라 하면, 예의 비율은

$$p = p_s \pi + (1 - p_s)(1 - \pi)$$

이며, 이로부터

$$p_s = \frac{p - (1 - \pi)}{2\pi - 1}$$

을 얻는다. 따라서

$$\hat{p}_s = \frac{\hat{p} - (1 - \pi)}{2\pi - 1}$$

이며,

$$\mathbb{E}[\hat{p}_s] = p_s, \hat{V}(\hat{p}_s) = \frac{1}{(2\pi - 1)^2} \frac{\hat{p}(1 - \hat{p})}{n}$$

Chapter 10

비균등 확률추출

10.1 PPS 추출

Definition 44. 관심변수 y_i 가 얼마나 크지를 대략적으로 나타내는 크기척도에 비례하도록 표본을 복원추출하는 방법을 *PPS* 추출이라고 한다. 모집단이 $\{y_1, y_2, \dots, y_N\}$ 이고 각 원소 i 에서 크기척도가 M_i 일 때, 원소 i 의 일회 추출확률은

$$p_i = \frac{M_i}{\sum_{i=1}^N M_i}$$

이다. 이때 모총계에 대한 비편향추정량은

$$\hat{\tau} = \frac{1}{n} \sum_{i=1}^n \frac{y_i}{p_i}$$

이며, 이를 *Hansen-Hurwitz(HH)* 추정량이라 한다.

Theorem 44. *HH* 추정량의 비편향 분산 추정량은

$$\hat{V}(\hat{\tau}) = \frac{1}{n(n-1)} \sum_{i=1}^n \left(\frac{y_i}{p_i} - \hat{\tau} \right)^2$$

이다.

10.1.1 PPS 집락추출

Definition 45. 집락추출에서 *PPS* 추출을 수행하는 경우, 집락의 크기를 크기척도로 이용할 수 있다. 그렇다면 i 번째 집락 관측값들의 평균을 \bar{y}_i 라 할 때

$$\frac{y_i}{p_i} = \frac{y_i}{M_i} \times M = M \bar{y}_i$$

이므로,

$$\hat{\tau}_{pps} = \frac{M}{n} \sum_{i=1}^n \bar{y}_i, \quad \hat{\mu}_{pps} = \frac{1}{n} \sum_{i=1}^n \bar{y}_i$$

이다. 또한 그들의 분산추정량은

$$\hat{V}(\hat{\tau}_{pps}) = \frac{M^2}{n(n-1)} \sum_{i=1}^n (\bar{y}_i - \hat{\mu}_{pps}), \quad \hat{V}(\hat{\mu}_{pps}) = \frac{1}{n(n-1)} \sum_{i=1}^n (\bar{y}_i - \hat{\mu}_{pps})$$

로 주어진다. 이는 첫 단계를 *PPS*로 추출하는 모든 다단계 추출에서도 동일하다.

Chapter 11

분산추정법

Note 25. 좋은 분산 추정량의 성질로는 아래를 생각해볼 수 있다.

- 비편향이거나, 편향이 매우 작을 것
- 분산 추정량의 분산이 작아 안정적일 것
- 음수 값을 취하지 않을 것
- 계산이 복잡하지 않을 것

Note 26. 비균등 확률추출의 경우 HT 추정량의 분산을 구하는 방법으로는 음의 분산추정량을 얻을 수 있다. 이러한 문제를 해결하기 위해,

$$\hat{V}(\hat{Y}_{HT}) = \frac{1}{n(n-1)} \sum_{i=1}^n \left(\frac{ny_i}{\pi_i} - \hat{Y}_{HT} \right)^2$$

을 **단순분산추정량**으로 대응적으로 이용할 수 있다. 일반적으로 이는 보수적인 분산추정법이다.

11.1 선형화 분산 추정법

Definition 46. 만약 \bar{y} 가 참값 \bar{Y} 에 대하여

$$\bar{y} = \bar{Y} + O_p(n^{-1/2})$$

를 만족하고, $g(\bar{y})$ 를 추정량으로 사용한다면,

$$g(\bar{y}) = g(\bar{Y}) + \nabla g(\bar{Y})^T (\bar{y} - \bar{Y}) + O_p(n^{-1})$$

이며, 분산 추정량은

$$\hat{V}(g(\bar{y})) = \sum_{i=1}^p \sum_{j=1}^p \frac{\partial g(\bar{y})}{\partial y_i} \frac{\partial g(\bar{y})}{\partial y_j} \widehat{\text{Cov}}(\bar{y}_i, \bar{y}_j)$$

으로 주어진다. 이때 \bar{y} 는 p 차원이다.

11.2 복제치 분산 추정법

Definition 47. **랜덤 그룹 방법**은 G 개의 표본그룹을 만든 후 각각에서 점추정치를 구하고, 그들의 변동으로부터 분산을 추정하는 방법이다. 독립적 랜덤 그룹법에서는

1. 주어진 표본추출방법을 따라 첫째 표본 $A_{(1)}$ 과 그로부터 θ 에 대한 $\hat{\theta}_{(1)}$ 을 구한다.
2. 동일한 방법으로 $A_{(2)}$ 를 뽑고 $\hat{\theta}_{(2)}$ 를 구한다.
3. 동일한 방식으로 G 개의 표본 그룹을 뽑고 $\hat{\theta}_{(1)}, \dots, \hat{\theta}_{(G)}$ 를 구한다.
4. 모수에 대한 최종 점추정량으로

$$\hat{\theta} = \frac{1}{G} \sum_{i=1}^G \hat{\theta}_{(i)}$$

를, 분산추정량으로

$$\hat{V}(\hat{\theta}) = \frac{1}{G(G-1)} \sum_{i=1}^G (\hat{\theta}_{(i)} - \hat{\theta})^2$$

를 얻는다.

Definition 48. 잭나이프 방법을 이용해 분산을 추정할 수도 있다. i 번째 관측값을 제외한 $n-1$ 개의 표본으로부터 얻은 추정량을 $\hat{\theta}^{(-i)}$ 라 할 때,

$$\hat{V}(\hat{\theta}) = \frac{n-1}{n} \sum_{i=1}^n (\hat{\theta}^{(-i)} - \hat{\theta})^2$$

를 잭나이프 분산추정량으로 이용할 수 있다.

Chapter 12

무응답과 무응답대체법

Definition 49. 무응답은 조사 단위 자체가 응답을 하지 않는 단위무응답과, 일부 항목에 대해서만 응답을 하지 않는 항목무응답으로 나눌 수 있다. 단위무응답의 경우 재조사나 무응답가중치조정을 통하여 처리하고, 항목무응답의 경우에는 결측값대체를 통하여 처리한다.

12.1 단위무응답의 처리

Definition 50. 가중치조정법에서는 응답자들의 가중치를 조정하여 추정량의 편향을 줄이려 한다. 무응답이 없을 때 HT 추정량이

$$\hat{Y}_{HT} = \sum_{i \in A} \frac{1}{\pi_i} y_i$$

이며, 응답확률을 ϕ_i 라 하면

$$\hat{Y}_{NWA} = \sum_{i \in A_R} \frac{1}{\pi_i \phi_i} y_i$$

이 된다. ϕ_i 는 층정보 혹은 보조변수 등을 통해 추정할 수 있다. 이외에도 모집단에 대한 정보를 통해 사후 층화와 유사한 방식으로 적절히 가중치를 조정할 수 있다.

Definition 51. 재조사를 하는 경우를 고려해 보자. 먼저 전체 N 명 중 응답할 사람이 N_R , 무응답한 사람이 N_M 명이라 하자. 그리고 일차 표본 크기가 n_R, n_M 이며, 재조사를 통해 무응답자 중 ν 의 비율만큼에게 조사를 다시 완료했다고 하자.

모평균에 대한 비편향 점추정량은

$$\bar{y}^* = \frac{n_R}{n} \bar{y}_R + \frac{n_M}{n} \bar{y}_M$$

이다. 이때 \bar{y}_R 은 n_R 명에게 얻은 관심변수 평균, \bar{y}_M 은 νn_M 명에게 얻은 관심변수 평균이다. 그리고 그 분산추정량은

$$\hat{V}(\bar{y}^*) = \left(1 - \frac{n}{N}\right) \frac{s^2}{n} + \frac{W_2 s_2^2}{n} \left(\frac{1}{\nu} - 1\right)$$

이다. s^2 은 전체 표본에서 얻은 분산추정량, $W_2 = N_M/N$, s_2^2 은 무응답 표본에서 얻은 분산추정량이다.

Theorem 45. 조사에 드는 비용을

$$C = nc_0 + n_R c_1 + \nu n_M c_2$$

라고 하자. 이때의 최적재조사비율은

$$\nu = \sqrt{\frac{c_0 + c_1 N_R / N}{c_2} \times \frac{\sigma_2^2}{\sigma^2 - W_2 \sigma_2^2}}$$

이며, 분산 V_0 를 위한 최소표본크기는

$$n = \frac{N(\sigma^2 + (\frac{1}{v} - 1)W_2\sigma_2^2)}{NV_0 + \sigma^2}$$

이다.

12.2 항목무응답의 처리

Definition 52. 항목무응답은 적당한 방식으로 결측된 값을 추정하여 대체함으로써 해결한다. 결측자료에 대한 최적예측치, 회귀모형 등을 사용할 수 있다.