

## 다차원 충화에서 선형계획법을 이용한 표본배정 방법

최재혁<sup>1)</sup>, 남궁 평<sup>2)</sup>

### 요 약

다차원충화에서 선형계획법을 이용한 표본배정 방법은 Winkler(1990, 2001), Sitter와 Skinner(1994, 2002)가 제안하였다. 이 방법들은 표본크기가 총 개수보다 크지 않는 경우에 공통적으로 선형계획법을 이용하여 표본배정을 실시하였다. 반복 비율 적합방법(IPF), 일반화 반복 비율 적합(GIFP), SS 방법을 통해 셀 값을 결정하고 선형계획법을 이용하여 표본의 배정확률을 통해 표본배정을 실시한다. 이 3가지 방법들로 표본을 배정하고 평균 및 분산추정량을 비교한다.

주요용어 : 선형계획법, 반복 비율 적합 방법(IPF), 일반화 반복 비율 적합(GIFP)

### 1. 서 론

모집단을 두 개 이상의 변수를 사용해서 충화하는 경우를 다차원 충화라고 한다. 모집단을 다차원 충화하는 경우에 추정오차를 구하기 위해서는 각 층에서 두 개 이상의 표본을 추출해야 한다. 즉, 모집단이  $R \times C$  개의 층으로 구성되어 있다면 적어도 표본의 수가  $2 \times R \times C$  개 이상이어야 한다. 보통 다차원 충화 추출에서는 비율배정을 통해 각 층에 표본을 배정한다. 하지만 이것은 표본크기가 충화된 층의 개수보다 크지 않을 경우 기대되는 층의 크기가 매우 작을 뿐더러 정수로 마무리되어야 하는 비율적 할당의 특성에 큰 방해가 될 것이다.

다차원 충화에서의 표본배정 방법으로 Winkler(1990, 2001)가 제안한 반복 비율 적합 방법(IPF 방법), 일반화 반복 비율 적합 방법(GIFP 방법)과 Sitter와 Skinner(1994, 2002)가 제안한 SS 방법이 있는데 이 방법들은 모두 선형계획법(Linear Programming)을 이용한다. 이 방법들은 표본크기가 충화된 층의 개수보다 크지 않는 경우에 한해서 사용되는 표본 배정 방법이다.

본 논문에서는 이차원 충화에서 선형계획법을 이용하여 IPF 방법 및 GIFP 방법과 SS 방법을 알아보고 각 추정량들을 비교하고자 한다.

### 2. 선형계획법을 이용한 표본배정

선형계획법을 통해 표본을 배정하는 방법은 표본크기를 선형계획법을 통해 해로 구하는 것이 아니라 표본배정확률  $p(x)$ 를 해로 구하는 방법이다. 따라서 표본배정에 사용되는 목적함수 및 제약식은 다음과 같다.

$$\textcircled{1} \text{ 목적함수 : } \min \{ c_1 p(x_1) + c_2 p(x_2) + \dots + c_n p(x_n) \}$$

1) 성균관대학교 경제학부 통계학과 박사과정, E-mail:leonash@skku.edu

2) 성균관대학교 경제학부 통계학과 교수, E-mail:namkung@skku.ac.kr

$$\textcircled{2} \text{ 제약조건 : } \begin{cases} \sum_{i=1}^n p(x_i) = 1 \\ \sum_{i=1}^n m_i p(x_i) = n_i \\ p(x_i) \geq 0 \\ i = 1, 2, \dots, n \end{cases}$$

여기서  $p(x_i)$ 는  $i$ 번째 표본배열이 선택될 확률이고  $c_i$ 는 주변합의 손실값이 된다. 주변합의 손실값이란 주변합이 반올림하면서 생기는 손실값을 의미한다.  $m_i$ 는 표본배정을 위해 모든 배열들이고  $n_i$ 는 비율배정이나 우리가 적합하여 얻어진 배열이다. 위의 목적함수와 제약식을 통해 표본배열 확률이 결정되면 그 값을 통해 표본배정을 결정하는 것이 다차원 충화에서 선형계획법을 이용한 표본배정방법이 된다.

### 3. 반복비율적합 방법(IPF)과 일반화 반복 비율 적합 방법(GIFP)

#### 3.1 칸 도수 추정

반복비율적합(Iterative Proportional Fitting)은 주변합을 통해 셀 크기를 추정한다. 먼저  $x_{ij}^s$ 를  $s$ 번째 반복의 표준화 칸 값이라고 하면  $x_{ij}^0 = x_{ij}$ 은 비율배정을 통한 셀 크기인 관측값이 된다. 그리고  $x_{i+}^*$ 와  $x_{+j}^*$ 는 표준화 주변합이다. 다음 식을 통해 반복적합하게 된다.

$$x_{ij}^s = \left( \frac{x_{ij}^{s-1}}{x_{i+}^{s-1}} \right) x_{i+}^*, \quad x_{ij}^{s+1} = \left( \frac{x_{ij}^s}{x_{+j}^s} \right) x_{+j}^*$$

$$| x_{ij}^{2k} - x_{ij}^{2k-2} | < \delta$$

여기서  $k$ 는 반복주기이다. 위 두 개의 식을 반복의 첫 번째 주기로 하여 허용오차  $\delta$ 에 이를 때까지 반복하게 된다. 이러한 주변합에 의한 반복계산법은 정확도  $\delta$ 에 이를 때까지 정확한 값에 수렴하게 된다. 그 수렴된 값을 통해 선형계획법을 이용, 표본배정을 실시하게 된다.

GIFP(Generalized Iterative fitting Procedure) 방법은 분류적 적합으로 Dykstra'의 일반화 반복 비율 적합(GIFP)에 의해 실현된다. 그 적합 과정은 다음과 같다.(L.Dykstra, 1985)

1.  $s_{11} = r$ ,  $p_{11} = \pi_1(s_{11})$ 라고 하고  $s_{12} = p_{11} = r(p_{11}/s_{11})$ 라고 생각하자.  $s_{11}(k) = 0$  이면  $p_{11}(k) = 0$  이다. 0/0은 1이 된다.
2.  $p_{12} = \pi_2(s_{12})$ 이고  $s_{13} = p_{12} = r(p_{11}/s_{11})(p_{12}/s_{12})$ 이다.
3. 계속해서 반복하면  $s_{1t} = p_{1(t-1)} = r(p_{11}/s_{11}) \dots (p_{1(t-1)}/s_{1(t-1)})$  이므로  $p_{1t} = \pi_t(s_{1t})$ 이고  $s_{21} = r(p_{12}/s_{12}) \dots (p_{1t}/s_{1t})$  이므로  $p_{2t} = \pi_t(p_{1t}/s_{1t})$ 이다.
4.  $p_{21} = \pi_1(s_{21})$ 이라고 하면  $s_{22} = r(p_{21}/s_{21})(p_{13}/s_{13}) \dots (p_{1t}/s_{1t})$ 이고 이 값은  $p_{22} = \pi_{21}/(p_{12}/s_{12})$ 의 값과 같다.
5. 계속해서 반복하면 일반적인 다음의 식을 얻을 수 있다.

$$s_{ni} = r \frac{p_{n1}}{s_{n1}} \dots \frac{p_{n(i-1)}}{s_{n(1-1)}} \frac{p_{(n-1)(i+1)}}{s_{(n-1)(i+1)}} \dots \frac{p_{(n-1)t}}{s_{(n-1)t}} = \begin{cases} p_{(n-1)t} \left( \frac{p_{(n-1)t}}{s_{(n-1)t}} \right)^{-1} & \text{if } i = 1 \\ p_{n(i-1)} \left( \frac{p_{(n-1)i}}{s_{(n-1)i}} \right)^{-1} & \text{if } 2 \leq i \leq t \end{cases}$$

위의 방법을 통해 반복 계산하면 GIFP 방법에 의한 셀 값을 추정할 수 있다. 이렇게 얻어진 셀 값을 통해 선형계획법을 이용하여 표본크기를 결정할 수 있다. GIFP 방법은 각 셀 간의 변동량을 최소로 하는 방법이므로 상호 관련 있는 모집단 수에 의해 칸내(그룹내) 표본 배분을 실현할 수 있다. 추가적으로 충화를 필요로 하는 주변값이 선형관계인 경우에는 GIFP 방법은 고전적 IPF 방법과 동등한 결과를 얻는다.

### 3.2 표본배정 및 추정량

다면량 표본추출 방법에 정의되는 주변값  $m_j (j=1, \dots, s)$ 의 집합이 있다고 하자. 각  $m_j$ 는 하나의 충화변수로 충화된 표본크기들이다. 하나 이상의 충화변수로 정의되는 모집단 크기를  $N_i (i \in I)$ 라고 하면 IPF 방법과 GFIP 방법에 의해 이것은  $g_i (i \in I)$ 로 수렴하게 된다. 배열  $g_i (i \in I)$ 은 반드시 다음을 만족해야 한다.

$$\sum_{i \in I_j} g_{ij} = m_j, \quad j = 1, \dots, s \quad \text{and} \quad g_i \leq N_i, \quad i \in I$$

여기서  $I_j$ 는 주변값  $m_j (j=1, \dots, s)$ 에 대한  $I$ 의 부분집합이다.

다음과 같이 양의 정수로 주변값  $m_j (j=1, \dots, s)$ 을 가지고 양의 정수값  $p_k (k=1, \dots, t)$ 가 존재하는 배열  $M_{ik} (i \in I, k=1, \dots, t)$ 을 찾는 것이 목적이다.

$$\sum_{k=1}^t p_k = 1 \quad \text{and} \quad \sum_{k=1}^t p_k M_{ik} = g_i, \quad i \in I$$

위의 식은 기대값  $g_i (i \in I)$ 를 가지는 양의 정수 행렬을 만들어내는 가능성 있는 구조를 산출한다. 이런 배열을 찾았다면 단지 확률적으로 비율크기  $p_1$ 를 가지는 배열  $M_{il} (i \in I)$ 를 선택하고 나서 모든  $i \in I$ 인 칸  $i$ 에서 크기  $M_{il}$ 인 표본을 선택한다.

IPF 방법 및 GIFP 방법으로 적합시킨 결과를 가지고 선형계획법을 이용하여 표본을 배정한다. 첫 번째  $M_0$ 는 IPF 방법 및 GIFP 방법에 의한 배열과 같고 계속해서  $M_k (k=1, \dots, t)$ 을 계산하면 선형계획법 과정에 의해 양의 정수로만 이루어진 배열을 찾을 수 있다.

IPF 방법 및 GIFP 방법에 대한 평균과 분산추정량을 구하는 방법은 포함확률을 이용하는 힐드비츠와 톰슨(Horvitz-Thompson) 추정량을 이용한다(Winkler, 2001). IPF 방법 및 GIFP 방법에서 평균과 분산추정량은 다음과 같이 계산된다.

$$\bar{y} = \frac{1}{N} \sum_i^I \left( \frac{N_i}{M_0} \right) \sum_j^n y_{ij}$$

$$\widehat{Var}(\bar{y}) = \frac{1}{N^2} \sum_i^I \left( \frac{n_i}{M_0} - 1 \right) \left( \sum_j^n y_{ij} \right)^2 + \frac{1}{N^2} \sum_{i \neq i}^I \left( \frac{n_i}{M_0} - 1 \right) \left( \frac{n_j}{M_0} - 1 \right) \left( \sum_j^n y_{ij} \right) \left( \sum_j^n y_{ij} \right)$$

여기서  $N$ 은 모집단 크기,  $i$ 는 각 셀,  $n_i$ 은 각 셀의 표본크기,  $M_0$ 은 IPF방법 및 GIFP방법으로 적합시킨 셀 크기,  $y_{ij}$ 는  $i$ 번째 셀에서 선택된 표본값이다.

따라서 모집단 총합 추정량은  $\hat{\tau} = \sum_i^I \left( \frac{N_i}{M_0} \right) \sum_j^n y_{ij}$ 이다.

#### 4. Sitter와 Skinner 방법 : SS방법

##### 4.1 칸 도수 추정

먼저 2차원 충화를 보면  $N$ 개의 모집단은  $R \times C$ 의 분할표로 분류되어 있다. 2단 추출 과정을 고려해 볼 때 첫 번째로 표본크기  $n_{ij}$ 를 특별한 랜덤 과정을 따르는 셀이라 하고  $s$ 를  $R \times C$  배열( $n_{ij}, i = 1, \dots, R, j = 1, \dots, C$ )로 정의하고 가능한 배열  $S$  집합에서 각  $s$ 의 확률  $p(s)$ 을 배정한다.  $s$ 에 대한  $n_{ij}$ 의 독립을 강조하기 위해  $n_{ij}(s)$ 라고 쓴다. 두 번째로  $n_{ij}(s)$  값들의 단순임의표본은 셀  $ij$ 으로부터 추출된다. 모든 배열의 집합  $S_n$ 가 되는  $S$ 를 제한한다. 여기서  $P_{ij} = N_{ij}/N$ 는 각 셀의 반응비율이다. 아래의 식이 제약조건이 된다.

$$\sum_{i=1}^R \sum_{j=1}^C n_{ij}(s) = n$$

$$\sum_{s \in S_n} n_{ij}(s) p(s) = n P_{ij} \quad \text{for } i = 1, \dots, R, j = 1, \dots, C$$

따라서 다음과 같은 문제를 해결함으로써 표본  $s$ 의 ‘바람직한 설계’의 기대되는 부족을 최소화하는 표본설계  $p(s)$ 을 선택하는 것을 가정한다.

$$\underset{p \in P}{\text{minimize}} \sum_{s \in S_n} w(s)p(s), \quad 0 \leq p(s) \leq 1 \quad \text{for all } s \in S_n$$

$w(s)$ 는 특정화된 표본  $s$ 에 대한 손실함수이고  $P$ 는 다음을 조건으로 하는  $S_n$ 에 대한 가능한 표본설계의 클래스인 일정한 제약조건에 종속되는 문제점이 있다.

위의 제한된 식은  $\sum_{s \in S_n} p(s) = 1$ 를 뜻한다. 목적함수와 일정한 제약조건과 일정하지 않은 제약조건 모두  $p(s)$ 에 대해 선형관계이다. 반면 이러한 문제점은 미지의  $p(s), s \in S_n$ 에 대해 선형계획법을 통해 직접 해결될 수 있다. 이 해결방법의 어려움은  $S_n$ 에서 원소의 수가 종종 매우 크게 되거나 또는 미지의 수가 매우 클 때 선형계획법에 의해 결과가 도출되기 어렵게 되는 계산상의 문제점이 있다는 것이다. 그러므로  $S_n$ 의 부분집합에 관심을 두고 제한하는 것은 바람직한 방법이다. 하나의 자연스러운 제약조건은  $n_{ij}(s)$ 가  $I_{ij} = [nP_{ij}]$ 와 같거나 가장 큰 정수가  $nP_{ij}$ 나  $I_{ij} + 1$ 보다 적은 배열  $s$  대해서만 오직 고려한다는 것이다.

$\tilde{n}_{ij}(s) = n_{ij}(s) - I_{ij}, r_{ij} = nP_{ij} - I_{ij}$ 라고 하면 제약조건은 다음과 같다.

$$\begin{aligned} & \underset{p \in P}{\text{minimize}} \sum_{s \in S_n} w(s)p(s) \\ & \sum_{s \in S_n} \tilde{n}_{ij}(s)p(s) = r_{ij} \end{aligned}$$

$$\sum_{s \in S_n} p(s) = 1, \quad 0 \leq p(s) \leq 1 \quad \text{for all } s \in S_n$$

여기서  $S_{\tilde{n}}$ 는 모든 원소가 0 또는 1이고 원소의 합이  $\tilde{n} = n - \sum_i I_{ij}$ 인  $R \times C$  배열의 집합이다. 물론 모든  $I_{ij}$ 가 0이면 이것은 이전과 같은 문제점이 발생한다.

선형계획법의 컴퓨터 계산상 과정에서 가장 중요한  $S_{\tilde{n}}$ 의 원소의 수는 이제  $\binom{RC}{\tilde{n}}$ 이다. 이 숫자는 여전히 매우 클 수 있다. 그러나 조금 축소하면 손실함수  $w(s)$ 의 알맞은 선택으로 나타날 수 있다. 이러한 접근법을 통해 손실함수  $w(s)$ 을 선택하는 방법으로 선택된 표본  $s$ 가 다음과 같은 주변합 제한이 요구된다.

$$|n_{i.}(s) - nP_{i.}| < 1 \quad i = 1, \dots, R$$

$$|n_{.j}(s) - nP_{.j}| < 1 \quad j = 1, \dots, C$$

$$n_{i.}(s) = \sum_j n_{ij}(s), \quad n_{.j}(s) = \sum_i n_{ij}(s), \quad P_{i.} = \sum_j P_{ij}, \quad P_{.j} = \sum_i P_{ij}$$

이러한 제한조건은  $S_n$  집합으로부터의 선택된 표본  $s$ 가 위와 같은 조건을 만족하지 못하면 배제시키거나 더 간단히  $w(s)$ 을 효과적으로 유한하게 적용함으로써 접근방법은 조절될 수 있다. 이러한 전통적인 접근이 가지고 있는 문제점은 최적화를 해결할 방법이 존재하지 않는다는 것이다. 그러나 다음과 같은 손실함수를 사용한다면 문제점이 다소 해결될 것이다.

$$w(s) = \sum_{i=1}^R (n_{i.}(s) - nP_{i.})^2 + \sum_{j=1}^C (n_{.j}(s) - nP_{.j})^2$$

최적 해결은 항상 충분히 큰  $S_n$  집합 사이에 존재할 것이다. 실제로 유한한 집합  $S_n$ 를 위의 조건식에 따르게 하거나 혹은 이들의 부분집합인 표본으로 제한하는 것은 컴퓨터 계산상과 필요에 의해 집합을 확장하는데 유리함으로 작용할 것이다. 해결 방법을 찾을 때까지 위의 제한식에서 1에서 2로 바꿈으로써 얻어진다.

#### 4.2 표본배정 및 추정량(SS방법)

선형계획법을 통한 문제 해결을 위한 손실함수는 다음과 같다.

$$w(s) = \sum_{i=1}^R (n_{i.}(s) - nP_{i.})^2 + \sum_{j=1}^C (n_{.j}(s) - nP_{.j})^2$$

$I_{ij}$  값은  $n_{ij} = I_{ij} + \tilde{n}_{ij}(\tilde{s})$ 으로 계산된다. 그것은  $p(s) > 0$ 인 각  $s$ 가 정확한 실험설계의 주변값과 어울리는 주변값  $n_{i.}(s)$ 과  $n_{.j}(s)$ 를 가지는 해결방법으로 완성된다.

이와 같은 방법으로 가능한 표본  $S_n$ 은 각 셀에  $[nP_{ij}]$ 나  $[nP_{ij}] + 1$ 의 값을 가지는 표본크기  $n_{ij}$ 를 갖게 된다.  $[nP_{ij}]$ 은  $nP_{ij}$ 와 같거나 작은 정수값을 가진다.

$\tilde{n}_{ij} = n_{ij} - [nP_{ij}]$ ,  $r_{ij} = nP_{ij} - [nP_{ij}]$ 로 표현되는 표본크기는  $E(\tilde{n}_{ij}) = r_{ij}$ 의 조건을 만족해야 한다. 여기서  $\tilde{n}_{ij} = 0$  or 1이고  $0 \leq r_{ij} \leq 1$ 이다. 따라서 선형계획법에 의해  $\tilde{n}_{ij}$ 을 구할 수 있고 각 셀의 표본크기는  $[nP_{ij}] + \tilde{n}_{ij}$ 가 된다. 그러므로 표본크기는 일반적인 손실없이

$n_{ij} = 0, 1$  나  $0 \leq r_{ij} = nP_{ij} < 1$ 로 계산한다.

마지막으로 3차원 이상의 L차원의 충화추출에서는 같은 방법을 적용하는데 손실함수의 형태만 달라진다. 그것은 이전 정보에 의해 계산된 세 개 이상의 충화 요인들의 가중값이 포함된다.

$$w(s) = v_1 \sum_{i=1}^{R_1} (n_{i..}(s) - nP_{i..})^2 + \cdots + v_L \sum_{k=1}^{R_L} (n_{...k}(s) - nP_{...k})^2$$

여기서  $v_1, \dots, v_L$ 은 이전 정보에 의한 L개의 충화 요인들의 평균의 충간 분산의 추정값으로 구성된다.

SS방법의 분산추정량을 구하는 방법은 앞선 방법과 마찬가지로 포함확률을 이용하는 호르비츠와 톰슨(Horvitz-Thompson) 추정량을 이용한다(Sitter, Skinner, 1994, 2002). 분산추정량을 구하기 위해 우선 각 표본 셀의 포함확률을 계산하여야 한다. 만약 표본크기가 2 이상을 경우는 각각의 표본 단위에 대해 포함확률을 따로 계산해야 한다. 따라서 표본크기가 1 이상인 표본 셀의 포함확률은 다음과 같이 계산한다.  $A_c$ 은 주변포함확률이고  $B_c$ 은 결합포함확률이다.

$$\pi_c = \frac{n_c}{N_c}, \quad \pi_{cc'} = \frac{n_c(n_c-1)}{N_c(N_c-1)}$$

$$A_c = \frac{I_c(I_c+2r_c-1)}{N_c(N_c-1)}, \quad B_{cc'} = \frac{I_c I_{c'} + r_c I_c + r_{c'} I_{c'} + r_{cc'}}{N_c N_{c'}}$$

여기서  $c$ 는 셀( $c = 1, \dots, ij$ ),  $N_c$ 는 모집단 셀 크기,  $N$ 은 전체 모집단 크기,  $I_c = n_c - \tilde{n}_c$ ,  $r_c = nP_c - I_c$ ,  $r_{cc'} = \tilde{n}_c \tilde{n}_{c'}$ 이다. 결국 위의 포함확률을 이용하여 다음과 같은 식으로 분산추정량을 유도할 수 있다. 따라서 SS 방법에서의 평균과 분산추정량은 다음과 같이 계산된다.

$$\bar{y} = \frac{1}{N} \sum_c^i N_c \bar{y}_c$$

$$\widehat{Var}(\bar{y}) = \frac{1}{2n^2} \sum_c^i \sum_k^n \sum_{k' \neq k} \left( \frac{n^2}{N^2} - A_c \right) (y_{ck} - y_{ck'})^2 + \frac{1}{2n^2} \sum_c^i \sum_{c' \neq c} \sum_{kk'} \left( \frac{n^2}{N^2} - B_{cc'} \right) (y_{ck} - y_{c'k'})^2$$

### 참고문헌

- [1] Randy R. Sitter and C.J. Skinner(1994). "Multi-way Stratification by Linear Programming", *Survey Methodology*.
- [2] William E. Winkler(1987). "An Application of Multi-purpose Survey Sampling", *American Statistical Association, Proceeding of the Section on Survey Research Methods*.
- [3] William E. Winkler (1990). "On Dykstra's Iterative Fitting Procedure", *The Annals of Probability*.
- [4] William E. Winkler (2001). "Multi-way Survey Stratification and Sampling", *U.S. Bureau of the Census, Statistical Research Division Report*.
- [5] William G. Cochran (1977). "Sampling Techniques-third edition", *John Wiley & Sons*.
- [6] Wilson Lu and Randy R. Sitter (2002). "Multi-way Stratification by Linear Programming Made Practical", *Survey Methodology*.