

임의로 관측중단된 두 표본 자료에 대한 카이제곱 검정방법¹⁾

김 주 한²⁾, 김 정 란³⁾

요 약

두 모집단에서 임의로 관측중단된 두 표본을 얻었을 때, 두 모집단의 분포가 같다는 가설을 검정하기 위한 카이제곱 검정방법이 제안되었다. 여기서 제안된 통계량은 대립가설이 두 모집단의 분포가 같지 않다는 양측가설일 때 쓰일 수 있다. 귀무가설이 사실일 때 제안된 통계량의 극한분포는 카이제곱 분포가 된다. 두 가지 형태의 카이제곱 검정통계량이 제안되었는데, 하나는 product-limit 추정치로 부터 얻은 관측된 칸(cell) 확률의 차이들의 벡터의 이차형식으로 표현된 것이고, 다른 하나는 간단한 합의 모양으로 표현된 것이다. 두 형태의 검정통계량을 사용하여 암치료를 위한 화학요법 실험으로 부터 얻은 자료를 분석하여 보았다.

1. 서 론

임의로 관측중단된(randomly censored) 두 개의 표본의 분포를 비교하는 방법으로는 일반화된 Wilcoxon 검정법(Gehan(1965), Efron(1967))과 로그 순위 검정법(Mantel(1967), Peto and Peto(1972))이 많이 이용되고 있다. 이러한 검정법들은 대립가설이 한 분포가 다른 분포보다 확률적으로 크다는 단측가설이나 한 분포가 다른 분포보다 확률적으로 크거나 또는 작다는 양측가설에는 사용될 수 있지만, 대립가설이 단순히 두 분포가 같지 않다는 양측가설일 경우는 적당하지 않다. 두 분포가 같다는 가설을 같지 않다는 양측가설에 대하여 검정하는 방법으로 Koziol(1978)은 각 표본의 product-limit 추정치를 이용한 두 표본 Cramer-von Mises 형태의 통계량을 제안하였고, Koziol and Yuh(1982)는 두 product-limit 추정치의 차이를 이용하여 Kolmogorov-Smirnov, Kuiper, Cramer-von Mises 형태의 통계량을 제안하였다. Koziol과 Yuh는 그들이 제안한 통계량들의 극한분포가 관측중단되지 않은 자료에 사용되는 통계량들의 극한분포의 절단된 형태로 됨을 보였고, 두 표본의 관측중단 분포(censoring distribution)가 같은 경우에도 같은 방법이 적용될 수 있음을 보여주었다.

본 논문에서는 이러한 검정 방법들에 대한 대안으로 임의로 관측중단된 두 표본의 분포를 비교하는 카이제곱 검정방법을 제안하고자 한다. 새로이 제안될 검정통계량은 두 분포가 같다는 가정 하에 극한적으로 카이제곱 분포를 하게 되고 계산하기 쉬운 합의 모양으로 표현되기 때문에 다른 통계량보다 손쉽게 사용할 수 있다는 장점이 있다.

1) 이 연구는 1992년도 한국과학재단 연구비지원에 의한 결과임(과제번호 : 923-0100-002-1).

2) (305-764) 대전직할시 유성구 궁동 220번지, 충남대학교 자연과학대학 통계학과.

3) (305-764) 대전직할시 유성구 궁동 220번지, 충남대학교 자연과학대학 통계학과.

2. 카이제곱 검정통계량

$X_1^0, X_2^0, \dots, X_m^0$ 은 서로 독립이고 동일한 연속분포함수 F_0 을 따르는 양의 확률변수들이고, $Y_1^0, Y_2^0, \dots, Y_n^0$ 은 서로 독립이고 동일한 연속분포함수 G_0 을 따르는 양의 확률변수들이라 하자. X_i^0 과 Y_j^0 도 서로 독립이다. X_i^0 과 Y_j^0 은 각각 독립인 확률변수 $X_i^c (1 \leq i \leq m)$ 와 $Y_j^c (1 \leq j \leq n)$ 에 의해 오른쪽으로 부터 관측중단되어 X_i^0 과 Y_j^0 은 모두 직접 관찰될 수 없고, 대신에 우리는 임의로 관측중단된 자료를 얻게 된다. 여기서 양의 확률변수 $X_i^c (1 \leq i \leq m)$ 와 $Y_j^c (1 \leq j \leq n)$ 는 관측중단변수라 부르고, 서로 독립이며 각각 연속분포함수 F_c 와 G_c 를 따르는 모집단에서 추출된 확률 표본이다. 우리가 관찰하여 얻을 수 있는 임의로 관측중단된 두 표본 자료는 $(X_i, \delta_i), i=1, \dots, m, X_i = \min(X_i^0, X_i^c), \delta_i = I(X_i = X_i^0)$ 와 $(Y_j, \varepsilon_j), j=1, \dots, n, Y_j = \min(Y_j^0, Y_j^c), \varepsilon_j = I(Y_j = Y_j^0)$ 이다. 관찰된 X_i 와 Y_j 는 각각 분포함수 $H_X = 1 - (1 - F_0)(1 - F_c)$ 와 $H_Y = 1 - (1 - G_0)(1 - G_c)$ 를 따르는 모집단에서 얻은 확률 표본이라 생각할 수 있다. 우리가 검정하고자 하는 귀무가설은 $H_0: F_0 = G_0$ 이며 대립가설은 $H_1: F_0 \neq G_0$ 이다.

카이제곱 검정통계량을 유도하는 기본적인 방법은 구간 $(0, \infty)$ 를 $k+1$ 개의 칸(cell)으로 나누고 각 칸에서 관측된 칸 확률을 비교하는 것이다. 칸의 경계를 $0 = a_0 < a_1 < \dots < a_k < a_{k+1} = \infty$ 라 하면, i 번째 칸에서 관측된 칸 확률은 $\hat{F}_0(a_i) - \hat{F}_0(a_{i-1})$ 과 $\hat{G}_0(a_i) - \hat{G}_0(a_{i-1})$ 이다. 여기서 \hat{F}_0 과 \hat{G}_0 은 각각 F_0 와 G_0 의 product-limit 추정치이다. 두 개의 관측된 칸 확률의 차이를 구해보면

$$\begin{aligned} & (\hat{F}_0(a_i) - \hat{F}_0(a_{i-1})) - (\hat{G}_0(a_i) - \hat{G}_0(a_{i-1})) \\ &= (\hat{F}_0(a_i) - \hat{G}_0(a_i)) - (\hat{F}_0(a_{i-1}) - \hat{G}_0(a_{i-1})) \end{aligned}$$

이고, 카이제곱 통계량을 얻기 위해 우리는 k 개의 관측된 칸 확률 차이의 결합분포를 알아야 한다.

X_1, X_2, \dots, X_m 과 Y_1, Y_2, \dots, Y_n 이 크기 순서로 되어 있다고 가정하고 F_0 와 G_0 의 product-limit 추정치를 다음과 같이 정의하자.

$$F_0(t) = \begin{cases} 0 & , t < X_1 \\ 1 - \prod_{i: X_i \leq t} [(m-i)/(m-i+1)]^{\delta_i} & , X_1 \leq t < X_m \\ 1 & , t \geq X_m \end{cases}$$

$$\hat{G}_0(t) = \begin{cases} 0 & , t < Y_1 \\ 1 - \prod_{j: Y_j \leq t} [(n-j)/(n-j+1)]^{\epsilon_j} & , Y_1 \leq t < Y_n \\ 1 & , t \geq Y_n \end{cases}$$

Breslow and Crowley(1974)와 Gill(1983)의 결과에 의하면 확률과정 $\sqrt{m}(\hat{F}_0(t) - F_0(t))$ 와 $\sqrt{n}(\hat{G}_0(t) - G_0(t))$ 는 각각 m 과 n 이 ∞ 로 접근할 때 평균이 0이고 다음과 같은 공분산 함수를 가지는 가우스 확률과정(Gaussian process) $Z_1(t)$ 와 $Z_2(t)$ 로 수렴한다.

$$\begin{aligned} Cov(Z_1(s), Z_1(t)) &= (1-F_0(s))(1-F_0(t)) \alpha(s) , & 0 < s \leq t \\ \alpha(s) &= \int_0^s \frac{dF_0}{(1-F_0)^2(1-F_c)} \\ Cov(Z_2(s), Z_2(t)) &= (1-G_0(s))(1-G_0(t)) \beta(s) , & 0 < s \leq t \\ \beta(s) &= \int_0^s \frac{dG_0}{(1-G_0)^2(1-G_c)} \end{aligned}$$

이제 관측된 칸 확률 차이의 분포를 알아보기 위해 확률과정

$$Z_{mn}(t) = \sqrt{\frac{mn}{m+n}} (\hat{F}_0(t) - \hat{G}_0(t))$$

를 생각해 보자.

$$\begin{aligned} Z_{mn}(t) &= \sqrt{\frac{mn}{m+n}} (\hat{F}_0(t) - \hat{G}_0(t)) \\ &= \sqrt{\frac{n}{m+n}} \sqrt{m} (\hat{F}_0(t) - F_0(t)) - \sqrt{\frac{m}{m+n}} \sqrt{n} (\hat{G}_0(t) - G_0(t)) \\ &\quad + \sqrt{\frac{mn}{m+n}} (F_0(t) - G_0(t)) \end{aligned}$$

이므로 만약 m 과 n 이 ∞ 로 접근하고 그들의 비 m/n 이 어떤 양수 λ 에 가까이 가고 귀무가설 $H_0: F_0 = G_0$ 가 사실이라면 $Z_{mn}(t)$ 는 구간 $[0, T)$ 에서, 여기서 $T = \sup \{t: F_0(t) < 1\}$, 평균이 0이고 다음과 같은 공분산함수를 가지는 가우스 확률과정 $Z(t)$ 로 수렴하게 된다.

$$Cov(Z(s), Z(t)) = \frac{1}{1+\lambda} q(s) q(t) \alpha(s) + \frac{\lambda}{1+\lambda} r(s) r(t) \beta(s) , \quad 0 \leq s < t < T$$

여기서 $q(s) = 1 - F_0(s)$ 이고 $r(s) = 1 - G_0(s)$ 이다.

그러므로 각 칸의 경계에서 $Z_{mn}(t)$ 의 값 $Z_{mn}(a_i)$ 를 w_i ($i=1, \dots, k$)라 하면 확률 벡터 $W = (w_1, \dots, w_k)'$ 은 $Z_{mn}(t)$ 의 수렴성에 의해 평균이 0이고 분산-공분산 행렬이 Σ_w 인 다변량 정규분포로 수렴하게 된다. Σ_w 의 원소는 다음과 같이 표현될 수 있다.

$$\sigma_w(i, j) = \frac{1}{1+\lambda} q(a_i) q(a_j) \alpha(a_i) + \frac{\lambda}{1+\lambda} r(a_i) r(a_j) \beta(a_i), \quad i \leq j.$$

이제 $v_i = Z_{mn}(a_i) - Z_{mn}(a_{i-1}) = w_i - w_{i-1}$, $i=1, \dots, k$, $w_0=0$, 으로 정의하면 v_i 는 i 번째 칸에서 표준화된 관측된 칸 확률의 차이가 된다. 확률벡터 $V = (v_1, \dots, v_k)'$ 은

$$V = AW = \begin{bmatrix} 1 & 0 & \cdots & \cdots & 0 \\ -1 & 1 & 0 & \cdots & 0 \\ 0 & -1 & 1 & \vdots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & -1 & 1 \end{bmatrix} W$$

와 같이 표현되고, W 의 수렴성에 의해 V 는 평균이 0이고 분산-공분산 행렬이 $\Sigma_v = A \Sigma_w A'$ 인 정규분포로 수렴하게 된다. 그러므로 V 의 이차형식 $Q = V' \Sigma_v^{-1} V$ 는 자유도가 k 인 카이제곱 분포로 수렴하게 된다. Q 를 W 로 표현하면

$$Q = V' \Sigma_v^{-1} V = (AW)' (A \Sigma_w A')^{-1} (AW) = W' \Sigma_w^{-1} W \quad (1)$$

가 된다. Σ_w 는 우리가 모르는 F_0 , F_c , G_0 , G_c , λ 등에 의해 결정되므로, Q 를 검정통계량으로 사용하기 위하여 Σ_w 의 일치추정치 $\hat{\Sigma}_w$ 을 구하여야 한다. $\hat{\Sigma}_w$ 는 F_0 , F_c , G_0 , G_c , λ 대신에, \hat{F}_0 , \hat{F}_c , \hat{G}_0 , \hat{G}_c , $\hat{\lambda} = m/n$ 을 사용하여 구할 수 있다. 즉,

$$\begin{aligned} \hat{\sigma}_w(i, j) &= \frac{n}{m+n} \hat{q}(a_i) \hat{q}(a_j) \hat{\alpha}(a_i) + \frac{m}{m+n} \hat{r}(a_i) \hat{r}(a_j) \hat{\beta}(a_i), \quad i \leq j \\ \hat{q}(a_i) &= 1 - \hat{F}_0(a_i), \quad \hat{r}(a_i) = 1 - \hat{G}_0(a_i) \\ \hat{\alpha}(a_i) &= \int_0^{a_i} \frac{d \hat{F}_0}{(1 - \hat{F}_0)^2 (1 - \hat{F}_c)}, \quad \hat{\beta}(a_i) = \int_0^{a_i} \frac{d \hat{G}_0}{(1 - \hat{G}_0)^2 (1 - \hat{G}_c)}. \end{aligned}$$

$\hat{\alpha}(s)$ 와 $\hat{\beta}(s)$ 는 적분으로 표시되었지만 실제로 \hat{F}_0 과 \hat{G}_0 이 계단함수(step function)이기 때문에 좀 더 간단한 합의 모양으로 표현될 수 있다.

$$\begin{aligned} \hat{\alpha}(s) &= \int_0^s \frac{d\hat{F}_0}{(1-\hat{F}_c)(1-\hat{F}_0)^2} = \int_0^s \frac{1}{1-\hat{F}_c} d\left(\frac{1}{1-\hat{F}_0}\right) \\ &= \sum_{i:x_i \leq s} \frac{1}{1-\hat{F}_c(x_i)} \left(\frac{1}{1-\hat{F}_0(x_i)} - \frac{1}{1-\hat{F}_0(x_{i-1})} \right) \\ &= \sum_{i:x_i \leq s} \left(\frac{1}{\prod_{j=1}^i \left(\frac{m-j}{m-j+1}\right)} - \frac{1}{\prod_{j=1}^{i-1} \left(\frac{m-j}{m-j+1}\right)} \cdot \frac{1}{\left(\frac{m-i}{m-i+1}\right)^{1-\delta_i}} \right) \end{aligned}$$

여기서 $\delta_i=0$ 이면 합산기호 안의 항이 0이 되므로

$$\hat{\alpha}(s) = \sum_{i:x_i \leq s} \left(\frac{m}{m-i} - \frac{m}{m-i+1} \right) \delta_i = \sum_{i:x_i \leq s} \frac{m}{(m-i)(m-i+1)} \delta_i$$

가 되고, 같은 방법으로

$$\hat{\beta}(s) = \sum_{i:y_i \leq s} \frac{n}{(n-i)(n-i+1)} \epsilon_i$$

가 된다. 위의 추정치들을 사용하여 얻은 Σ_w 의 추정치 $\hat{\Sigma}_w$ 을 (1)의 식에 대입하면 $H_0: F_0=G_0$ 를 검정하기 위한 카이제곱 통계량 \hat{Q} 는 다음과 같이 표현된다.

$$\hat{Q} = W' \hat{\Sigma}_w^{-1} W$$

\hat{Q} 는 H_0 이 사실일 때 근사적으로 자유도가 k 인 카이제곱 분포를 하게 된다.

\hat{Q} 를 계산하는 것이 어려운 문제는 아니지만, $H_0: F_0=G_0$ 이 사실일 때 좀 더 간단한 합 의 모양으로 나타내지는 카이제곱 통계량을 다음과 같이 얻을 수 있다.

H_0 이 사실일 때 X_i^0 와 Y_j^0 의 공통 분포함수를 $F^*=F_0=G_0$ 라 하면 $\sigma_w(i, j)$ 는 다음과 같 이 표현될 수 있다.

$$\begin{aligned} \sigma_w(i, j) &= d(a_i) d(a_j) c(a_i) \\ c(a_i) &= \frac{1}{1+\lambda} a(a_i) + \frac{\lambda}{1+\lambda} \beta(a_i) \\ d(a_i) &= 1-F^*(a_i) \end{aligned}$$

$d(a_i)=d_i, c(a_i)=c_i$ 로 간단히 표현하면

$$\Sigma_w = \begin{bmatrix} c_1 d_1^2 & c_1 d_1 d_2 & \cdots & \cdots & c_1 d_1 d_k \\ & c_2 d_2^2 & \cdots & \cdots & c_2 d_2 d_k \\ & & \ddots & & \vdots \\ & & & \ddots & \\ & & & & c_k d_k^2 \end{bmatrix}$$

이 되고, $\Sigma_w = T' T$ 가 되는 삼각행렬 T 는 다음과 같이 주어진다.

$$T = \begin{bmatrix} d_1\sqrt{c_1} & d_2\sqrt{c_1} & \cdots & \cdots & d_k\sqrt{c_1} \\ & d_2\sqrt{c_2-c_1} & \cdots & \cdots & d_k\sqrt{c_2-c_1} \\ & & 0 & \ddots & \vdots \\ & & & & d_k\sqrt{c_k-c_{k-1}} \end{bmatrix}$$

그러면

$$Q = W' \Sigma_w^{-1} W = W' (T' T)^{-1} W = (T'^{-1} W)' (T'^{-1} W) = W^{*'} W^*$$

가 되므로, 우리는 Q 를 합의 모양으로 나타낼 수 있다.

T 의 역행렬을 구해 보면

$$T^{-1} = \begin{bmatrix} \frac{1}{d_1\sqrt{c_1}} & -\frac{1}{d_1\sqrt{c_2-c_1}} & & & \\ & \frac{1}{d_2\sqrt{c_2-c_1}} & \ddots & & 0 \\ & & \ddots & \ddots & \\ & & & \ddots & \\ & 0 & & & -\frac{1}{d_{k-1}\sqrt{c_k-c_{k-1}}} \\ & & & & \frac{1}{d_k\sqrt{c_k-c_{k-1}}} \end{bmatrix}$$

이므로

$$W^* = T'^{-1} W = \begin{bmatrix} \frac{w_1}{d_1\sqrt{c_1}} \\ \frac{w_2}{d_2\sqrt{c_2-c_1}} - \frac{w_1}{d_1\sqrt{c_2-c_1}} \\ \vdots \\ \frac{w_k}{d_k\sqrt{c_k-c_{k-1}}} - \frac{w_{k-1}}{d_{k-1}\sqrt{c_k-c_{k-1}}} \end{bmatrix}$$

이 되고

$$\begin{aligned} Q &= W^{*'} W^* \\ &= \sum_{i=1}^k \left(\frac{w_i}{d_i\sqrt{c_i-c_{i-1}}} - \frac{w_{i-1}}{d_{i-1}\sqrt{c_i-c_{i-1}}} \right)^2 \\ &= \sum_{i=1}^k \frac{1}{c_i-c_{i-1}} \left(\frac{w_i}{d_i} - \frac{w_{i-1}}{d_{i-1}} \right)^2 \end{aligned} \quad (2)$$

로 나타내진다.

위 식에 c_i 와 d_i 의 일치추정치를 대입하면 합의 모양으로 표현된 카이제곱 통계량을 얻을 수 있다. c_i 의 일치추정치는 λ , $\alpha(a_i)$, $\beta(a_i)$ 대신에 m/n , $\hat{\alpha}(a_i)$, $\hat{\beta}(a_i)$ 를 대입하면 다음과 같이 표현된다.

$$\begin{aligned} \hat{c}_i &= \frac{n}{m+n} \hat{\alpha}(a_i) + \frac{m}{m+n} \hat{\beta}(a_i) \\ &= \frac{mn}{m+n} \left(\sum_{j: X_j \leq a_i} \frac{\delta_j}{(m-j+1)(m-j)} + \sum_{j: Y_j \leq a_i} \frac{\epsilon_j}{(n-j+1)(n-j)} \right) . \end{aligned}$$

$d_i = 1 - F^*(a_i)$ 의 일치추정치는 공통 분포함수 F^* 의 추정치를 두 표본을 합하여 구하는 것이 바람직하지만, 실제로 두 표본의 관측중단분포들이 다르기 때문에 두 표본을 합하여 F^* 의 추정치를 구할 수 없다. 그러므로 각각의 표본에서 구할 수 있는 $1 - \hat{F}_0(a_i)$ 와 $1 - \hat{G}_0(a_i)$ 의 가중평균인

$$\hat{d}_i = \frac{m}{m+n} (1 - \hat{F}_0(a_i)) + \frac{n}{m+n} (1 - \hat{G}_0(a_i))$$

를 d_i 의 추정치로 사용한다.

$$\begin{aligned} w_i &= \sqrt{\frac{mn}{m+n}} (\hat{F}_0(a_i) - \hat{G}_0(a_i)) = \sqrt{\frac{mn}{m+n}} (\hat{r}_i - \hat{q}_i) \\ \hat{r}_i &= \hat{\alpha}(a_i) = 1 - \hat{G}_0(a_i) , \quad \hat{q}_i = \hat{\beta}(a_i) = 1 - \hat{F}_0(a_i) \end{aligned}$$

로 표현되고, 이것과 \hat{d}_i , \hat{c}_i 을 (2)의 식에 대입하면 다음과 같은 간단한 모양의 카이제곱 통계량 \hat{Q}_1 을 얻는다.

$$\hat{Q}_1 = \sum_{i=1}^k \frac{(f_i - f_{i-1})^2}{b_i - b_{i-1}}$$

여기서, $f_i = (\hat{r}_i - \hat{q}_i) / \hat{d}_i$, $b_i = b_{1i} + b_{2i}$ 이고

$$b_{1i} = \sum_{j: X_j \leq a_i} \frac{\delta_j}{(m-j+1)(m-j)} , \quad b_{2i} = \sum_{j: Y_j \leq a_i} \frac{\epsilon_j}{(n-j+1)(n-j)} .$$

3. 예 제

2절에서 구한 카이제곱 검정방법을 이용하여 Koziol(1978)이 사용한 자료를 분석하려고 한다. 자료는 백혈병을 치료하는 새로운 화학요법제의 효과를 보기 위한 연구로 부터 얻어진 자료이다. 백혈병에 걸려 있는 60마리의 쥐를 30마리씩 두 그룹으로 임의로 나눈 후, 한 그룹은 아무

<표 1> 쥐의 생존기간과 PL 추정치

대 조 군		처 리 군	
생 존 기 간	PL 추 정 치	생 존 기 간	PL 추 정 치
15.4	.03333	4.7	.03333
15.4	.06667	5.4	.06667
15.7	.10000	7.1	.10000
16.1*	.10000	7.5	.13333
16.5*	.10000	8.1	.16667
16.6	.13600	8.3*	.16667
16.9	.17200	8.5	.20139
17.9	.20800	8.6	.23611
18.4	.24400	10.0	.27083
18.5	.28000	10.4	.30556
18.9	.31600	11.1	.34028
19.0	.35200	12.1*	.34028
19.1	.38800	13.8	.37693
19.2	.42400	15.0	.41358
19.4	.46000	15.1	.45023
19.7	.49600	15.3	.48688
19.8	.53200	17.6	.52353
20.4*	.53200	21.0	.56019
20.8	.57100	22.7	.59684
20.9*	.57100	23.9	.63349
21.3	.61390	24.1	.67014
21.4	.65680	27.4	.70679
21.4	.69970	31.8	.74344
21.4*	.69970	33.5	.78009
21.5	.74975	34.9	.81674
21.7	.79980	35.5*	.81674
22.0	.84985	35.6*	.81674
22.2	.89990	35.9	.87783
22.5	.94995	37.4	.93891
23.8	1.00000	38.2	1.00000

런 치료를 하지 않고(대조군), 다른 그룹은 새로운 화학요법제로 치료하고(처리군), 쥐들의 생존 기간을 측정하였다.

각 군의 쥐들의 생존 기간과 각 관측치에서 product-limit 추정치는 <표 1>과 같다. 관측중 단된 자료는 관측치에 *를 붙여 표시하였다. 처리군에서는 4개, 대조군에서는 5개의 자료가 관측중단되었다.

처리군과 대조군의 생존 분포가 같다는 가설을 검정하기 위해 구간 $(0, \infty)$ 를 8개의 칸으로 나누고 각 칸의 경계는 9.50, 15.50, 18.00, 19.50, 21.45, 22.30, 33.00으로 하였다. 칸의 수가 정해지면 칸의 경계는 귀무가설이 사실일 때 각 칸의 확률이 같게 되도록 정하는 것이 검정력을 높

이는 방법이라고 알려져 있다. 이 예제에서는 귀무가설이 사실일 때 공통 분포함수 F^* 를 알지 못하므로 그것의 추정치로 $F^* = (\hat{F} + \hat{G})/2$ 를 사용하여 각 칸의 확률이 거의 같도록 정하였다. 칸의 경계와 각 칸의 경계에서 $\hat{q}_i, \hat{r}_i, b_{1i}, b_{2i}$ 를 계산한 결과는 <표 2>와 같다.

<표 2>의 수치를 이용하여 카이제곱 검정통계량의 값을 구해보면 $\hat{Q} = 91.74$ 이고, $\hat{Q}_1 = 23.99$ 이다. \hat{Q} 과 \hat{Q}_1 은 모두 귀무가설이 사실일 때 자유도가 7인 카이제곱 분포를 하므로 p-값은 0.0000과 0.0011이다. 그러므로 우리는 대조군과 처리군의 생존 분포가 같지 않다는 결론을 내릴 수 있다. 여기서 \hat{Q} 과 \hat{Q}_1 의 값이 큰 차이를 보이는 이유는 실제로 대조군과 처리군의 분포에 많은 차이가 있기 때문으로 판단된다. \hat{Q} 은 공통 분포함수 F^* 의 추정치를 사용 안하고 \hat{F} 과 \hat{G} 을 별개로 사용하여 계산하기 때문에 비교하고자 하는 두 분포함수가 조금만 달라져도 값이 커질 가능성이 있다. 다시말하면 \hat{Q} 을 사용하면 검정력은 높아질지 모르지만, 귀무가설을 너무 자주 기각함으로써 우리가 정한 유의수준보다 높은 수준의 제 1종의 오류 (Type I error)를 범할 가능성이 있다. 그러므로 본인의 견해로는 \hat{Q} 보다 \hat{Q}_1 을 사용하는 것이 더 안전하다고 생각된다. 이와같은 견해는 시뮬레이션을 통하여 확인될 수 있을 것이다.

<표 2> 칸의 경계와 계산된 $\hat{q}_i, \hat{r}_i, b_{1i}, b_{2i}$ 값

칸의 경계	\hat{q}_i	\hat{r}_i	b_{1i}	b_{2i}
$a_1= 9.50$.79861	1.00000	.01045	0.00000
$a_2= 15.50$.51312	.93333	.03350	.00238
$a_3= 18.00$.47647	.79200	.03900	.00916
$a_4= 19.50$.47647	.54000	.03900	.03037
$a_5= 21.45$.43981	.30030	.04541	.09106
$a_6= 22.30$.43981	.10010	.04541	.42439
$a_7= 33.00$.25656	0.00000	.10493	.92439

본인은 본 논문에서 제시한 통계량 \hat{Q} 과 \hat{Q}_1 뿐만아니라 서론에서 언급한 기존의 여러 검정통계량을 시뮬레이션을 통하여 비교하는 것을 향후 연구과제중 하나로 생각하고 있다.

참고문헌

- [1] Breslow, N. and Crowley, J. (1974). A large sample study of the life table and product limit estimates under random censorship, *Annals of Statistics*, Vol. 2, 437-453.
- [2] Efron, B. (1967). The two sample problem with censored data, Proceedings of 5th Berkeley Symposium, Vol. 5, 831-853.
- [3] Gehan, E. A. (1965). A generalized Wilcoxon test for comparing arbitrarily single censored samples, *Biometrika*, Vol. 52, 203-223.
- [4] Gill, R. (1983). Larger sample behavior of the product-limit estimator on the whole line, *Annals of Statistics*, Vol. 11, 49-58.
- [5] Kaplan, E. L. and Meier, P. (1958). Nonparametric estimation from incomplete observations, *Journal of the American Statistical Association*, Vol. 53, 457-481.
- [6] Kim, J. H. (1993). Chi-square goodness-of-fit tests for randomly censored data, *Annals of Statistics*, Vol. 21, 1621-1639.
- [7] Koziol, J. (1978). A two-sample Cramer-von Mises test for randomly censored data, *Biometrical Journal*, Vol. 20, 603-608.
- [8] Koziol, J. and Yuh, Y. S. (1982). Omnibus two-sample test procedures with randomly censored data, *Biometrical Journal*, Vol. 24, 743-750.
- [9] Mantel, N. (1966). Evaluation of survival data and two new rank statistics arising in its consideration, *Cancer Chemotherapy Reports*, Vol. 50, 163-170.
- [10] Peto, R. and Peto, J. (1972). Asymptotically efficient rank invariant test procedures (with discussion), *Journal of the Royal Statistical Society, Series A*, Vol. 135, 185-207.

Two-Sample Chi-Square Test for Randomly Censored Data⁴⁾

Joo-Han Kim⁵⁾, Jeong-Ran Kim⁶⁾

Abstract

A two sample chi-square test is introduced for testing the equality of the distributions of two populations when observations are subject to random censorship. The statistic is appropriate in testing problems where a two-sided alternative is of interest. Under the null hypothesis, the asymptotic distribution of the statistic is a chi-square distribution. We obtain two types of chi-square statistics ; one as a nonnegative definite quadratic form in difference of observed cell probabilities based on the product-limit estimators, the other one as a summation form. Data pertaining to a cancer chemotherapy experiment are examined with these statistics.

4) This research is supported by the KOSEF, 1992.(No. 923-0100-002-1)

5) Department of Statistics, Chungnam National University, 220 Gung-Dong Taejeon, 305-764, KOREA.

6) Department of Statistics, Chungnam National University, 220 Gung-Dong Taejeon, 305-764, KOREA.