

## 희박다항분포확률에 대한 국소최대우도 추정량

백 장선<sup>1)</sup>

요 약

$\boldsymbol{p} = (p_1, p_2, \dots, p_k)^T$ 의 확률벡터를 가진 다항분포로부터 관측된 칸 돏수(cell frequency) 벡터가  $\boldsymbol{N} = (N_1, N_2, \dots, N_k)^T$  이며  $\sum_{j=1}^k N_j = n$  이라 하자. 총돏수  $n$  이 칸의 총갯수  $k$ 에 비하여 상대적으로 매우 작을 때 이러한 이산형 자료를 희박다항분포자료(sparse multinomial data)라 한다. 이러한 희박다항분포자료의 칸들이 순서화 되어 있을 때 우리는  $i$ 번째 칸의 확률  $p_i$ 를 돏수 추정량  $N_i/n$  들을 평활함으로써 추정 할 수 있다. Aerts, et al.(1997)과 Baek(1998) 등에 의해 제안된 국소최소제곱 기준에 근거한 국소다항커널추정량은 희박점근일치성의 좋은 성질을 가짐에도 불구하고 확률추정지가 음수값을 가질 수 있는 단점을 내포하고 있다. 본 연구에서는 이러한 단점을 극복하기 위하여 국소최대우도 기준에 근거한 새로운 커널추정량을 제안하고, 그것의 점근적 성질을 연구하였다.

주요 용어 : 희박다항분포, 국소최대우도, 국소다항추정량

### 1. 서론

순서화된 범주를 갖는 범주형 자료를 분석하고자 할 때 그 자료가 각 범주에 대하여  $\{N_j\}$ ,  $j = 1, \dots, k$ 의 칸 돏수로 구성되어 있다고 하자. 이때  $k$ 는 칸의 수이며 총돏수는  $n = \sum_{j=1}^k N_j$  이다. 이러한 다항자료의 첫번째 관심은 칸 확률  $\boldsymbol{p} = \{p_j\}$ 를 추정하는 것이다. 우리가 추정하려는 칸 확률  $p_i$ 는  $[0, 1]$ 에서 연속인 함수  $f(\cdot)$ 에 의해 결정된다고 가정하자. 즉,  $p_i = \int_{(i-1)/k}^{i/k} f(u) du$ ,  $i = 1, \dots, k$ 이며  $f(\cdot)$ 는  $(t+1)$ 차 미분가능하다고 가정한다. 칸 확률은 일반적으로 돏수 추정량  $\bar{p}_i = N_i/n$ 을 사용하여 왔다. 그러나 이 추정량은 각 칸에서의 관측돏수가 많을 때 유용하며 희박한 다항자료에서는 일치성을 만족하지 못한다.

1) (500-757) 광주광역시 북구 용봉동 300 전남대학교 통계학과 부교수

따라서 인접한 칸의 정보를 차용한 비모수적 추정량들이 개발되었고 그 성능은 뜻수 추정량  $\overline{p}_i$  보다 나은 결과를 보여준다.

$x_l = (l-1/2)/k$ ,  $l=1, \dots, k$  를 등간격을 갖는 각 구간의 중심점이라 하면, Aerts, et al.(1997)과 Baek(1998)에서 사용한 커널 추정량은  $(x_l, \overline{p}_l)$ ,  $l=1, \dots, k$  를 평활하여 구한 커널 추정량이었다. 그들이 사용한 기준은 회귀분석에서 즐겨 사용하는 국소최소제곱법이며, 따라서  $i$ 번째 칸 확률에 대한 추정량은  $\overline{p}_i$  들을  $t$ 차 다항 함수로 평활시킨

$$\sum_{j=1}^k [\overline{p}_j - \beta_0 - \dots - \beta_t(x_i - x_j)^t]^2 K_h(x_i - x_j)$$

를 최소화하는  $\hat{\beta} = (\hat{\beta}_0, \dots, \hat{\beta}_t)$  중에서 상수항  $\hat{\beta}_0$ 이다. 이때  $K$ 는 커널함수이며  $h$ 는 평활모수이다. 그러나 이러한 국소최소제곱법에 의한 국소다항추정량은 회귀오차가 정규분포를 따른다는 회귀분석 상황에 보다 적합한 것이며 다항확률에 적용 됐을 때 음수값을 취할 수 있는 단점을 가지고 있다. 따라서 다항분포 자료에는 최소제곱법보다는 적절한 우도함수에 기반한 비음수의 추정량을 구축하는 것이 바람직 하다.

$\sum_{i=1}^k N_i = n$ 이 주어졌을 때 다항관측벡터  $(N_1, N_2, \dots, N_k)$ 는  $k$ 개의 독립적인 포아송확률 변수로 간주할 수 있다(Kendall & Stuart 1979, p449). 즉,  $N_i \sim Poisson(np_i)$ 이며  $N_i$ 들은 독립적이다.  $k$ 개의 독립적 포아송 확률변수  $N_i$ 의 로그우도함수  $L$ 은

$$L = \prod_{i=1}^k \frac{e^{-(np_i)} (np_i)^{N_i}}{N_i!}$$

이며, 로그우도함수는

$$\ln L = \sum_{i=1}^k [N_i \ln(np_i) - np_i - \ln(N_i!)]$$

이다. 이 로그우도함수에서 상수항을 제거하여도 최대화를 달성할 수 있으므로, 상수항

$\sum_{i=0}^k \ln(N_i!)$ 를 제거한 새로운 로그우도함수를

$$l = \sum_{i=1}^k [N_i \ln(np_i) - np_i] \tag{1}$$

라고 하자.

모수적 일반화선형모형에서는 종종 회귀함수  $\mu(x) = E(Y|X=x)$ 의 변환함수

$\eta(x) = g(\mu(x))$ 를 선형으로 모형화한다. 이때  $g$ 를 링크함수라 한다. 특히  $g = (b')^{-1}$ 를 만족하는  $g$ 를 정준링크(canonical link)라 부른다.

실제상황에서 우도함수는 모르지만 평균과 분산의 관계는 알 수 있는 경우가 종종 존재한다. 이 경우 로그우도함수  $\ln q_{Y|X}(y)$  대신 준우도함수(quasi-likelihood function)  $Q(\mu(x), y)$ 를 이용하여  $\mu(x)$ 에 관한 추론을 수행한다. 만약 조건부 분산이 알려진 양의 함수  $V$ 에 대하여  $Var(Y|X=x) = V(\mu(x))$ 로 모형화 될 때, 이에 대응하는 준우도함수  $Q(w, y)$ 는

$$\frac{\partial}{\partial w} Q(w, y) = \frac{y-w}{V(w)}$$

를 만족하는 함수이다(McCullagh and Nelder 1989.) 준우도방법은 우도방법과 비슷하며 특히 우도함수가 알려져 있지 않을 때 대체하여 사용할 수 있는 방법이다. 또한 단일모수 지수족의 로그우도함수는  $V = b'' \cdot (b')^{-1}$ 인 준우도함수의 특별한 경우가 된다. 따라서 반응변수의 분포가 지수족에 속하고, 분산함수가 정확하게 규정되면 준우도추정방법은 최우추정법과 동일하다는 것을 알 수 있다.

자료  $(X_1, Y_1), \dots, (X_k, Y_k)$ 를 이용하여  $\mu(X)$ 를 추정하기 위해 최대화 시켜야 하는 준우도함수는

$$\sum_{i=1}^k Q(\mu(X_i), Y_i) = \sum_{i=1}^k Q(g^{-1}(\eta(X_i)), Y_i)$$

이다.

포아송 반응변수  $y$ 의 경우  $Q(w, y) = y \ln w - w$ 이며, 정준링크는  $g(u) = \ln(u)$ 임을 확인할 수 있다.  $i$ 번째 칸의 중심점  $X_i$ 와 그 칸의 뜻수  $N_i$ 로 이루어진 우리의 자료  $\{(X_i, N_i)\}_{i=1}^k$ 에서, 반응변수  $Y_i = N_i$ 는 평균  $\mu(X_i) = np_i$ 를 가진 포아송분포를 따른다. 이 때의 정준링크는  $\eta(x) = g(\mu(x)) = \ln(np)$  형태를 갖는다. 그러므로 최대화를 위한 준우도함수는

$$l = \sum_{i=1}^k Q(g^{-1}(\eta(X_i)), N_i) = \sum_{i=1}^k [N_i \ln(np_i) - np_i] \quad (2)$$

이다. (2)식은 로그우도함수 (1)과 정확히 일치한다.

## 2. 희박다항분포확률에 대한 국소최대우도 추정량

이제  $X=x$ 의 중심점을 갖는 칸에서의 칸 확률  $p$ 를 추정하기 위해 먼저  $\eta(x) = \ln(np)$ 에 대한 비모수적 추정량을 구한 뒤 그것을 역변환하는 전략을 취하기로 한다. 우리는  $x$ 점에서 국소적으로  $t$ 차 다항함수로서  $\eta(x)$ 를 추정하려고 한다. 이를 위해서는 자료를  $x$ 에 대해 중심화 시키고  $x$ 근처의 자료에 더 많은 중요성을 줄 수 있도록 우도함수를 가중화함으로써 가능하다. 즉, 커널  $K_h(X_i - x)$ 를 이용하여 가중화를 한다면 국소로그우도함수는

$$\begin{aligned} l^* &= \sum_{i=1}^k Q(g^{-1}(\beta_0 + \dots + \beta_t(X_i - x)^t), N_i) K_h(X_i - x) \\ &= \sum_{i=1}^k [N_i \{\beta_0 + \dots + \beta_t(X_i - x)^t\} - \exp\{\beta_0 + \dots + \beta_t(X_i - x)^t\}] K_h(X_i - x) \end{aligned} \quad (3)$$

이다.  $\hat{\beta} = (\hat{\beta}_0, \dots, \hat{\beta}_t)$ 가 위의 국소로그우도함수를 최대화시키는 추정모수라 할 때,  $\eta(x) = \ln(np)$ 에 대한 국소최대우도 커널추정량은  $\hat{\eta}(x; t, h) = \hat{\beta}_0$ 이며, 따라서  $p$ 에 대한 추정량은  $\hat{p}(x; t, h) = (1/n) \exp(\hat{\beta}_0)$ 이다. 따라서 추정치는 비음수를 보장한다.

$p$ 에 대한 추정량  $\hat{p}(x; t, h) = (1/n) \exp(\hat{\beta}_0(x; t, h))$ 에 대한 점근적 정규성은 [정리 1]과 같이 규명할 수 있다.

[정리 1]  $t > 0$ 이 홀수이고,  $k \rightarrow \infty$ 에 따라  $h = h_k \rightarrow 0$ ,  $kh^3 \rightarrow \infty$ 이라고 하자.  $x \in [h, 1-h]$ 일 때, 국소로그우도 추정량을  $\hat{p}(x; t, h)$ 라 하면,

$$\begin{aligned} & \frac{\sqrt{nhk}}{\sqrt{p} \int_A K_t(z; A)^2 dz} \left[ \hat{p}(x; t, h) - p \right. \\ & \left. - \left\{ \int z^{t+1} K_t(z) dz \right\} \left\{ \frac{\frac{\partial^{(t+1)}}{\partial x^{(t+1)}} \ln(np)}{(t+1)!} \right\} p h^{t+1} \{1 + O(h)\} \right] \xrightarrow{d} N(0, 1) \end{aligned} \quad (4)$$

이다. 만약  $x$ 가 경계점일 때는 식 (4)의  $\int_A K_t(z; A)^2 dz$ 와  $\int z^{t+1} K_t(z) dz$ 를 각각  $\int_{D_{x,h}} K_t(z; D_{x,h})^2 dz$ 와  $\int_{D_{x,h}} z^{t+1} K_t(z; D_{x,h})^2 dz$ 로 대체하면 역시 성립한다.

$t > 0$ 가 홀수일 때 점근적 편차는 내부와 경계에서 동일한 차수의 크기를 갖는다. 점근적 평균평방오차(AMSE ; asymptotic mean squared error)는 편차의 제곱과 분산의 합이므로  $x = x_i \in [h, 1-h]$ 에서의 추정량  $\hat{p}(x; t, h)$ 에 대한 AMSE는

$$\begin{aligned} \text{AMSE}(\hat{p}(x; t, h)) \\ = \left\{ \int z^{t+1} K_t(z) dz \right\}^2 \left\{ \frac{S_{(t+1)}(f, f^{(1)}, \dots, f^{(t+1)})}{(t+1)! k} \right\}^2 h^{2t+2} \\ + \frac{\left\{ \int_A K_t(z; A)^2 dz \right\} f(x)}{nk^2 h} \end{aligned}$$

이다.  $x = x_i$ 가 경계점일 때, 즉  $x = x_i \in [0, h) \cup (1-h, 1]$ 에서도 점근적 편차와 점근적 분산 모두 내부점일 때와 동일한 차수를 갖고 있으므로, 경계점에서의 AMSE =  $O(h^{2t+2}/k^2) + O((nkh)^{-1})$ 이다.

내부와 경계에서의 AMSE의 결과들을 통합하여  $\hat{p}(x; t, h)$ 의 전구간에서의 적합도의 척도인 MSSE(mean sum of squared error)를 다음과 같이 점근적으로 구할 수 있다. 내부구간을  $I = [h, 1-h]$ , 경계구간을  $B = [0, h) \cup (1-h, 1]$ 이라 할 때,  $\hat{p} = (\hat{p}(x_1), \dots, \hat{p}(x_k))$ 에 대하여

$$\begin{aligned} \text{MSSE}(\hat{p}) \\ \sim \frac{h^{2t+2}}{k} \left\{ \int z^{t+1} K_t(z) dz \right\}^2 \frac{\int S_{(t+1)}(f(u), \dots, f^{(t+1)}(u)) du}{\{(t+1)!\}^2} \\ + \frac{1}{nkh} \left\{ \int_A K_t(z; A)^2 dz \right\} \end{aligned}$$

이다.

한편 국소최소제곱법에 의한 칸 확률에 대한 국소다항커널 추정량의 MSSE는 점근적으로

$$\frac{h^{2t+2}}{k} \left\{ \int z^{t+1} K_t(z) dz \right\}^2 \frac{\int (f^{(t+1)}(u))^2 du}{\{(t+1)!\}^2} + \frac{1}{nkh} \int_A K_t(z; A)^2 dz$$

이다(Aerts, et al 1997).

최대우도국소다항커널 추정량  $\hat{p}(x; t, h)$ 의 MSSE 내 점근적 분산 공헌부분은 국소최소제곱법에 의해 추정된 국소다항커널 추정량의 그것과 정확히 일치한다. 또한 점근적 편차의 공헌부분은 국소최대우도방법에 의한 것이 조금 더 복잡하지만 두 방법 모두 동일한 차수  $O\left(\frac{h^{2t+2}}{k}\right)$ 를 갖고 있음을 확인할 수 있다.

$t > 0$ 이 홀수인 경우 MSSE ( $\hat{p}$ )를 최소화 시키는 최적평활모수  $h_{opt}$ 는

$$h_{opt} = \left[ \frac{\{(t+1)!\}^2 \int_A K_t(z; A)^2 du}{(2t+2) \left\{ \int z^{t+1} K_t(z) dz \right\}^2 \left\{ \int S_{(t+1)}(f(u), \dots, f^{(t+1)}(u)) du \right\} n} \right]^{1/(2t+3)}$$

이다. 따라서  $h_{opt}$ 을 사용했을 때 MSSE ( $\hat{p}(\cdot; t, h_{opt})$ ) =  $O\left(k^{-1}n^{-\frac{2t+2}{2t+3}}\right)$ 이다. 이것은 Hall and Titterington(1987)에 의해서 밝혀진 다항 간 확률들이  $(t+1)$ 차까지 미분가능할때의 추정량에 대한 MSSE의 최적 수렴율과 동일하다. 그러므로 우리의 국소최대우도 추정량은 최적 MSSE 수렴율을 달성함을 알 수 있다.

#### 참고문헌

- [1]. Aerts, M. A. , Augustyns, I. and Janssen P.(1997), "Smoothing Sparse Multinomial Data using Local Polynomial Fitting, " *Nonparameteric Statistics*, 8. 127-147.
- [2]. Baek, J. (1998), "A Local Linear Kernel Estimator for Sparse Multinomial Data," *Journal of the Korean Statistical Society*, 27, 515-529.
- [3]. Fan, J., Heckman, N. E. and Wand, M.P.(1995), "Local Polynomial Kernel Regression for Generalized Linear Models and Quasi-Likelihood Functions," *Journal of the American Statistical Association*, 90, 141-150.
- [4]. Hall, P, and Titterington, D. M. (1987), "On Smoothing Sparse Multinomial Data," *Australian Journal of Statistics*, 29, 19-37.
- [5]. Kendall, M. and Stuart, A. (1979), *The Advanced Theory of Statistics*, Vol. 2, 4th ed. Charles Griffin & Company, London.
- [6]. McCullagh , P. and Nelder, J. A. (1989), *Generalized Linear Models*, 2nd ed., Chapman and Hall, London.