

HAFTA 6

TAHMİN EDİCİLERDE ARANAN ÖZELLİKLER

Bir kitleyi karakterize eden o kitlenin parametreleridir. Kitle hakkında herhangi bir istatistiki sonuç çıkarım aslında kitle parametreleri hakkında bir sonuç çıkarımdır. Bir rasgele değişkenin dağılım fonksiyonu (veya olasılık fonksiyonu) kitle parametrelerine bağlıdır. Kitlenin parametre sayısı bir tane olabildiği gibi, birden fazla da olabilir. Örneğin, normal dağılımın iki tane parametresi vardır. Kitlenin parametresi hakkında tahminde bulunabilmek için deneyler tekrarlanır. Tekrar sayısı arttıkça, parametre hakkında daha iyi bilgi elde edileceği beklenir. Ancak, deney sayısının fazla olması bazen imkansız olduğu gibi bazen de pahalı olabilir. Böyle durumlarda, küçük örneklemeler ile parametre hakkında bilgi sahibi olmak istenebilir.

Bir parametre hakkında tahminde bulunmak için herhangi bir engel yoktur. Yani, bir parametre için değişik tahminler önerilebilir. En iyi denilebilecek bir tahminden daha iyi tahminler de yapılabilir. Dolayısı ile, “*iyi bir tahminden*” ne anlamamız gerektiği iyi tanımlanmalıdır. Bunun için, iyi bir tahminde aranan özelliklerin olması gerekir. Ancak bu özellikler kapsamında iyi bir tahminden söz edilebilir. Tahmin, önerilen bir tahmin edicinin değeri olduğundan, tahminden söz edilirken aslında tahmin ediciden söz edilmektedir. Bu bölümde, yaygın olarak kabul gören bazı özellikler incelenecektir.

7.1. Yeterlilik Özelliği (Sufficiency)

Bilinmeyen θ parametresi için yeterli bir tahmin edici, örneklem içinde parametre hakkındaki bilgiyi özetleyen tahmin edicidir. Yani, örneklem içinde parametre hakkında ne kadar bilgi varsa, hiçbir bilgi kaybı olmadan özetleyen bir tahmin edici, o parametre için yeterlidir.

X_1, X_2, \dots, X_n olasılık veya olasılık yoğunluk fonksiyonu $f(x; \theta)$ olan kitleden bir örneklem olsun. $T(X_1, X_2, \dots, X_n) = T(\underline{X})$ tahmin edicisi θ için yeterli ise, θ hakkında X_1, X_2, \dots, X_n örneklemeine bağlı olarak elde edilen bir sonuç sadece $T(\underline{X})$ tahmin edicisinin değerine bağlıdır. Yani, $\underline{x} = (x_1, x_2, \dots, x_n)'$ ve $\underline{y} = (y_1, y_2, \dots, y_n)'$ ayrı ayrı gözlemler ve $T(\underline{x}) = T(\underline{y})$ ise, θ hakkında X ler veya Y ler üzerinden yapılacak sonuç çıkarımlar aynıdır. X_1, X_2, \dots, X_n örnekleme için bazen \underline{X} gösterimi de kullanılacaktır.

Tanım 7.1.1 $T(\underline{X})$ verildiğinde, \underline{X} in koşullu dağılımı θ ya bağlı değilse, $T(\underline{X})$ 'e θ için *yeterli bir tahmin edici* denir ⊗

$\underline{X} = (X_1, X_2, \dots, X_n)'$ bir örneklem olmak üzere $P(\underline{X} = \underline{x} | T(\underline{X}) = t)$ koşullu olasılığı (sürekli durum için $f_{\underline{X}|T(\underline{X})=t}(\underline{x}|t)$ koşullu olasılık yoğunluk fonksiyonu) θ ya bağlı değilse $T(\underline{X})$, θ için yeterlidir. $T(\underline{X})$ tahmin edicisi yerine bazen T kullanılacaktır. Tanımdan da anlaşılacağı gibi, herhangi bir θ parametresi için yeterli istatistik tek değildir. T , θ için yeterli ise gözlenen \underline{X} ve \underline{Y} ler için $P_\theta(\underline{X} = \underline{x}) = P_\theta(\underline{Y} = \underline{x})$ dir. T yeterli olduğundan $P(\underline{X} = \underline{x} | T = t) = P(\underline{Y} = \underline{x} | T = t)$ dir. Ayrıca $\{\underline{X} = \underline{x}\} \subset \{T(\underline{X}) = T(\underline{x})\}$ olup $P_\theta(\underline{X} = \underline{x}) = P_\theta(\underline{Y} = \underline{x})$ eşitliği

$$\begin{aligned} P_\theta(\underline{X} = \underline{x}) &= P_\theta(\underline{X} = \underline{x}, T = t) = P(\underline{X} = \underline{x} | T = t) P_\theta(T = t) \\ &= P_\theta(\underline{Y} = \underline{x} | T = t) P_\theta(T = t) = P_\theta(\underline{Y} = \underline{x}, T = t) = P_\theta(\underline{Y} = \underline{x}) \end{aligned}$$

şeklinde elde edilir. Diğer taraftan, $P(\underline{X} = \underline{x} | T = t)$ koşullu olasılığı

$$P(\underline{X} = \underline{x} | T = t) = \frac{P_\theta(\underline{X} = \underline{x}, T = t)}{P_\theta(T = t)} = \frac{P_\theta(\underline{X} = \underline{x})}{P_\theta(T = t)} = \frac{p(\underline{x}; \theta)}{q(T(\underline{x}); \theta)}$$

şeklinde yazılabilir. Buna göre, aşağıdaki teoremi ispatsız olarak verebiliriz.

Teorem 7.1.1 T tahmin edicisinin θ için yeterli olması için gerek ve yeter koşul

$p(\underline{x}; \theta) / q(T(\underline{x}); \theta)$ oranının θ dan bağımsız olmasıdır \diamond

Örnek 7.1.1 a) X_1, X_2, \dots, X_n parametresi p olan Bernoulli dağılımından bir örneklem olsun.

$T = X_1 + X_2 + \dots + X_n$ tahmin edicisinin p için yeterli olup olmadığını araştıralım.

$T \sim \text{Binom}(n, p)$ olup olasılık fonksiyonu,

$$P_p(T = t) = \binom{n}{t} p^t (1-p)^{n-t}, \quad t = 0, 1, 2, \dots, n$$

şeklinde dir. $t = x_1 + x_2 + \dots + x_n$ için $p(\underline{x}; p) / q(T(\underline{x}); p)$ oranı p ye bağlı değilse T , p için yeterlidir. Teorem (7.1.1) e göre $t = x_1 + x_2 + \dots + x_n$ için bu oran,

$$\frac{p(\underline{x}; p)}{q(T(\underline{x}); p)} = \frac{P_p(\underline{X} = \underline{x})}{P_p(T = t)} = \frac{\prod_{i=1}^n P_p(X_i = x_i)}{P_p(T = t)} = \frac{\prod_{i=1}^n p^{x_i} (1-p)^{1-x_i}}{\binom{n}{t} p^t (1-p)^{n-t}} = \frac{p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i}}{\binom{n}{t} p^t (1-p)^{n-t}} = \frac{1}{\binom{n}{t}}$$

şeklinde olup p ye bağlı değildir. $T = \sum_{i=1}^n X_i$ tahmin edicisi p parametresi için yeterlidir.

b) X_1, X_2, \dots, X_n beklenen değeri μ olan normal dağılımdan bir örneklem olsun. $T = X_1 + X_2 + \dots + X_n \sim N(n\mu, n)$ olup, T nin μ için yeterli olup olmadığını inceleyelim. Bunun için, Teorem (7.1.1) deki oranın payı

$$\begin{aligned} p(\underline{x}; \mu) &= \prod_{i=1}^n f_{\mu}(x_i; \mu) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(x_i - \mu)^2\right) = \left(\frac{1}{2\pi}\right)^{n/2} \exp\left(-\frac{1}{2} \sum_{i=1}^n (x_i - \mu)^2\right) \\ &= \left(\frac{1}{2\pi}\right)^{n/2} \exp\left(-\frac{1}{2} \sum_{i=1}^n x_i^2 + \mu \sum_{i=1}^n x_i - \frac{n\mu^2}{2}\right) \end{aligned}$$

ve paydası

$$\begin{aligned} q(T(\underline{x}); \mu) &= q(t; \mu) = \frac{1}{\sqrt{2n\pi}} \exp\left(-\frac{1}{2n}(t - n\mu)^2\right) = \frac{1}{\sqrt{2n\pi}} \exp\left(-\frac{1}{2n}(t^2 - 2n\mu t + n^2\mu^2)\right) \\ &= \frac{1}{\sqrt{2n\pi}} \exp\left(-\frac{t^2}{2n} - \frac{n^2\mu^2}{2n} + \mu t\right) \end{aligned}$$

dir. $t = x_1 + x_2 + \dots + x_n$ için oran

$$\begin{aligned} \frac{p(\underline{x}; \mu)}{q(T(\underline{x}); \mu)} &= \frac{p(\underline{x}; \mu)}{q(t; \mu)} = \frac{\left(\frac{1}{2\pi}\right)^{n/2} \exp\left(-\frac{1}{2} \sum_{i=1}^n x_i^2 + \mu \sum_{i=1}^n x_i - \frac{n\mu^2}{2}\right)}{\frac{1}{\sqrt{2n\pi}} \exp\left(-\frac{t^2}{2n} + \mu t - \frac{n\mu^2}{2}\right)} \\ &= \frac{\sqrt{2n\pi}}{(2\pi)^{n/2}} \exp\left(-\frac{1}{2} \left[\sum_{i=1}^n x_i^2 - \frac{t^2}{n} \right]\right) \end{aligned}$$

şeklinde yazılır. Bu oran μ ye bağlı olmadığından T , μ için yeterlidir.

c) Benzer şekilde, X_1, X_2, \dots, X_n parametresi θ olan Poisson dağılımından bir örneklem olsun. $T = X_1 + X_2 + \dots + X_n \sim \text{Poisson}(n\theta)$ olup,

$$\frac{p(\underline{x}; \theta)}{q(T(\underline{x}); \theta)} = \frac{P_{\theta}(X = \underline{x})}{P_{\theta}(T = t)} = \frac{\prod_{i=1}^n P_{\theta}(X_i = x_i)}{P_{\theta}(T = t)} = \frac{e^{-n\theta} \theta^{\sum_{i=1}^n x_i} \prod_{i=1}^n \frac{1}{x_i!}}{e^{-n\theta} (n\theta)^t / t!} = \frac{t!}{n^t} \prod_{i=1}^n \frac{1}{x_i!}$$

oranı $t = x_1 + x_2 + \dots + x_n$ için θ parametresinden bağımsızdır. Yani T , θ için yeterlidir \oplus

Tanımdan hareketle yeterli istatistiğin bulunması bazen zor olabilir. Bir tahmin edici verildiğinde, onun yeterli olup olmadığı da araştırılabilir. Ancak yeterli tahmin ediciyi önceden kestirmek kolay olmayabilir. Aşağıdaki teorem yeterli istatistiği bulmak için önemli bir araçtır.

Teorem 7.1.2 (*Faktörizasyon Teoremi*) X_1, X_2, \dots, X_n olasılık veya olasılık yoğunluk fonksiyonu $f(x; \theta)$ olan kitleden bir örneklem olsun. T , θ için yeterli olması için gerek ve yeter koşul öyle $g(t; \theta)$ ve $h(x)$ fonksiyonları için, ortak olasılık ve olasılık yoğunluk fonksiyonunun $f(x; \theta) = g(T(x); \theta)h(x)$ şeklinde yazılabilesidir. g fonksiyonu $T(x)$ ve θ nin bir fonksiyonu olup h fonksiyonu ise sadece x in bir fonksiyonudur.

İspat: Kesikli durumu gözönüne alalım (sürekli durumda ispat Hogg, and Craig (1995) sayfa 318 de verilmiştir). T tahmin edicisi θ için yeterli olsun. Yeterliliğin tanımından $P(\underline{X} = \underline{x} | T = t)$ koşullu olasılığı θ ya bağlı değildir. Buradan, $h(\underline{x}) = P(\underline{X} = \underline{x} | T = t)$ ve $g(T(\underline{x}); \theta) = P_\theta(T = t)$ fonksiyonları seçildiğinde, $f(\underline{x}; \theta)$ ortak olasılık fonksiyonu,

$$f(\underline{x}; \theta) = P_\theta(\underline{X} = \underline{x}) = P_\theta(T = t)P(\underline{X} = \underline{x} | T = t) = g(T(\underline{x}); \theta)h(\underline{x})$$

şeklinde yazılabilir. Böylece, teoremin gerek kısmı ispatlanmış olur.

Şimdi, öyle $g(t; \theta)$ ve $h(x)$ fonksiyonları için ortak olasılık fonksiyonu

$$f(\underline{x}; \theta) = g(T(\underline{x}); \theta)h(\underline{x})$$

şeklinde yazılabilsin. $p(\underline{x}; \theta) / q(T(\underline{x}); \theta)$ oranı θ ya bağlı değilse T tahmin edicisi θ için yeterlidir. $A_{T(\underline{x})} = \{y : T(\underline{x}) = T(\underline{y})\}$ olmak üzere $T(\underline{x})$ fonksiyonu $A_{T(\underline{x})}$ kümesi üzerinde sabittir.

Ayrıca, T nin olasılık fonksiyonu, $q(T(\underline{x}); \theta) = \sum_{\underline{y} \in A_{T(\underline{x})}} q(T(\underline{y}); \theta)h(\underline{y})$ şeklinde

yazılabildiğinden Teorem (7.1.1) deki oran,

$$\begin{aligned} \frac{p(\underline{x}; \theta)}{q(T(\underline{x}); \theta)} &= \frac{g(T(\underline{x}); \theta)h(\underline{x})}{q(T(\underline{x}); \theta)} = \frac{g(T(\underline{x}); \theta)h(\underline{x})}{\sum_{\underline{y} \in A_{T(\underline{x})}} g(T(\underline{y}); \theta)h(\underline{y})} \\ &= \frac{g(T(\underline{x}); \theta)h(\underline{x})}{g(T(\underline{x}); \theta) \sum_{\underline{y} \in A_{T(\underline{x})}} h(\underline{y})} = \frac{h(\underline{x})}{\sum_{\underline{y} \in A_{T(\underline{x})}} h(\underline{y})} \end{aligned}$$

olup parametreden bağımsızdır. Yani T , θ için yeterlidir \diamond

Örnek 7.1.2 a) X_1, X_2, \dots, X_n parametresi p olan Bernoulli dağılımından bir örneklem olsun. $T = X_1 + X_2 + \dots + X_n$ nin p için yeterli olduğunu bir önceki örnekten biliyoruz. Şimdi, faktörizasyon teoremini kullanarak T nin yeterli olduğunu görelim. X lerin ortak olasılık fonksiyonu,

$$f(\underline{x}; p) = P_p(X = \underline{x}) = \prod_{i=1}^n P_p(X_i = x_i) = \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i}$$

$$= p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i} = p^{T(\underline{x})} (1-p)^{n-T(\underline{x})}$$

şeklinde olup, ortak olasılık fonksiyonu $g(T(\underline{x}); p) = p^{T(\underline{x})} (1-p)^{n-T(\underline{x})}$ ve $h(\underline{x}) = 1$ için

$$f(\underline{x}; p) = g(T(\underline{x}); p) h(\underline{x})$$

şeklinde yazılabildiğinden faktörizasyon teoremine göre T tahmin edicisi p için yeterlidir.

b) $N(\mu, \sigma^2)$ dağılımından bir örneklem X_1, X_2, \dots, X_n olsun. X_1, X_2, \dots, X_n rasgele değişkenlerinin ortak olasılık yoğunluk fonksiyonu, $T(\underline{x}) = \left(\sum_{i=1}^n x_i, \sum_{i=1}^n x_i^2 \right)$ için,

$$f(\underline{x}; \mu, \sigma^2) = \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 + \frac{\mu}{\sigma^2} \sum_{i=1}^n x_i - \frac{n\mu^2}{2\sigma^2} \right)$$

$$= \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} \exp\left(-\frac{n\mu^2}{2\sigma^2} \right) \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n x_i + \frac{\mu}{\sigma^2} \sum_{i=1}^n x_i \right)$$

$$= \left(\frac{1}{2\pi} \right)^{n/2} \left(\frac{1}{\sigma^2} \right)^{n/2} \exp\left(-\frac{n\mu^2}{2\sigma^2} \right) \exp\left[\left(\frac{\mu}{\sigma^2}, -\frac{1}{2\sigma^2} \right) \begin{pmatrix} \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i^2 \end{pmatrix} \right]$$

$$= \left(\frac{1}{2\pi} \right)^{n/2} \left(\frac{1}{\sigma^2} \right)^{n/2} \exp\left(-\frac{n\mu^2}{2\sigma^2} \right) \exp\left[\tilde{w}'(\mu, \sigma^2) T(\underline{x}) \right]$$

şeklinde yazılabilir. Buradan, ortak olasılık yoğunluk fonksiyonu

$$h(\underline{x}) = (1/2\pi)^{n/2} \text{ ve } g(T(\underline{x}); \mu, \sigma^2) = \left(\frac{1}{\sigma^2} \right)^{n/2} \exp\left(-\frac{n\mu^2}{2\sigma^2} \right) \exp\left[\tilde{w}'(\mu, \sigma^2) T(\underline{x}) \right]$$

fonksiyonları ile,

$$f(\underline{x}; \mu, \sigma^2) = g(T(\underline{x}); \mu, \sigma^2) h(\underline{x})$$

şeklinde yazılır. Faktörizasyon teoremine göre, $T(\underline{X}) = \left(\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2 \right)$ şeklindeki iki boyutlu

tahmin edici (μ, σ^2) için yeterlidir.

c) X_1, X_2, \dots, X_n parametresi θ olan düzgün dağılımdan bir örneklem olsun. X lerin olasılık yoğunluk fonksiyonu,

$$f(x; \theta) = \begin{cases} 1/\theta & , \quad 0 < x < \theta \\ 0 & , \quad d.y. \end{cases}$$

şeklindedir. Bu olasılık yoğunluk fonksiyonu

$$I_A(x) = \begin{cases} 1 & , \quad x \in A \\ 0 & , \quad x \notin A \end{cases}$$

gösterge fonksiyonu ile, $f(x; \theta) = \theta^{-1} I_{\{0 < x < \theta\}}(x)$ şeklinde de yazılabilir. Buna göre, X lerin ortak olasılık yoğunluk fonksiyonu $x_{(n)} = \max\{x_1, x_2, \dots, x_n\}$ için

$$\begin{aligned} f(\underline{x}; \theta) &= \prod_{i=1}^n f(x_i; \theta) = \frac{1}{\theta} I_{\{0 < x_{(1)} < \theta\}}(x_1) \frac{1}{\theta} I_{\{0 < x_{(2)} < \theta\}}(x_2) \dots \frac{1}{\theta} I_{\{0 < x_{(n)} < \theta\}}(x_n) \\ &= \frac{1}{\theta^n} I_{\{0 < x_{(n)} < \theta\}}(\underline{x}) \end{aligned}$$

dir. Buradan $g(T(\underline{x}); \theta) = \theta^{-n} I_{\{0 < x_{(n)} < \theta\}}(\underline{x})$ ve $h(\underline{x}) = 1$ fonksiyonları ile faktörizasyon teoreminden $T(\underline{X}) = X_{(n)}$ istatistiği θ için yeterlidir.

d) Olasılık yoğunluk fonksiyonu,

$$f(x; \theta) = \begin{cases} \theta x^{\theta-1} & , \quad 0 < x < 1 \\ 0 & , \quad d.y. \end{cases}$$

olan kitleden n – birimlik bir örneklem X_1, X_2, \dots, X_n olsun. Ortak olasılık yoğunluk fonksiyonu

$$f(\underline{x}; \theta) = \prod_{i=1}^n f(x_i; \theta) = \theta^n \prod_{i=1}^n x_i^{\theta-1} = \theta^n \left(\prod_{i=1}^n x_i \right)^{\theta} \prod_{i=1}^n \frac{1}{x_i} = g(T(\underline{x}); \theta) h(\underline{x})$$

olarak yazılabildiğinden, $T(\underline{X}) = \prod_{i=1}^n X_i$ tahmin edicisi, θ için yeterlidir. Burada,

$$g(T(\underline{x}); \theta) = \theta^n \left(\prod_{i=1}^n x_i \right)^{\theta} \quad \text{ve} \quad h(\underline{x}) = \prod_{i=1}^n \frac{1}{x_i}$$

dir ⊕

Faktörizasyon teoreminin uygulanabilmesi için X_1, X_2, \dots, X_n örnekleminin bağımsız aynı dağılımlı rasgele değişkenler olması zorunlu değildir. Ancak, daha önce örneklem denildiğinde bağımsız aynı dağılımlı rasgele değişkenlerin bir dizisini anlayacağımızı söylenmişti. Teoremin ispatında da, rasgele değişkenlerin bağımsızlığı dikkate alınmamıştır.

Herhangi bir θ parametresi için bir tane yeterli istatistik bulunduğunda, bu yeterli istatistiğin her birebir fonksiyonu da yeterlidir. Bunun için, T yeterli bir istatistik, r de herhangi bir birebir fonksiyon olsun. Bu durumda, $T^* = r(T)$ de θ için yeterlidir. T yeterli olduğundan öyle $g(t; \theta)$

ve $h(x)$ fonksiyonları vardır ki ortak olasılık yoğunluk fonksiyonu, $f(\underline{x}; \theta) = g(T(\underline{x}); \theta) h(\underline{x})$ şeklinde yazılabilir. Ayrıca r birebir olduğundan, $T = r^{-1}(T^*)$ dir. Buradan, $f(\underline{x}; \theta)$ ortak olasılık veya olasılık yoğunluk fonksiyonu

$$\begin{aligned} f(\underline{x}; \theta) &= g(T(\underline{x}); \theta) h(\underline{x} = g(r^{-1}(T^*(\underline{x})); \theta)) h(\underline{x}) \\ &= (g \circ r^{-1})(T^*(\underline{x}); \theta) h(\underline{x}) = g^*(T^*(\underline{x}); \theta) h(\underline{x}) \end{aligned}$$

şeklinde de yazılabilir. Faktörizasyon teoremine göre, $T^* = r(T)$ de θ için yeterlidir. Buna göre, Örnek (7.1.2a) daki $T = \sum_{i=1}^n X_i$ istatistiği p için yeterli olduğundan \bar{X}_n de p için yeterlidir. Benzer

şekilde, (b) deki $T(\underline{X}) = \left(\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2 \right)$ tahmin edicisi (μ, σ^2) için yeterli olup $T^*(\underline{X}) = (\bar{X}_n, S_n^2)$

iki boyutlu istatistiği de (μ, σ^2) için yeterlidir. Ayrıca, (d) de verilen $T = \prod_{i=1}^n X_i$ istatistik yeterli

olduğundan, $T^* = -\sum_{i=1}^n \ln(X_i)$ tahmin edicisi de yeterlidir.

7.2. Minimal Yeterlilik

Bir önceki kısımda, bir parametre için yeterli istatistiğin tek olmadığını, yeterli istatistiğin her birebir fonksiyonunun da aynı parametre için yeterli olduğunu gördük.

Tanım 7.2.1 (*minimal yeterli istatistik*) T^* istatistiği herhangi bir θ parametresi için yeterli olsun. Eğer bir T tahmin edicisi, T^* yeterli istatistiğinin bir fonksiyonu olarak yazılabiliyorsa, T ye θ için *minimal yeterlidir* denir \otimes

Bir parametre için, herhangi bir yeterli istatistik bulunduğu (faktörizasyon teoreminden), minimal yeterli istatistik bu istatistiğin bir fonksiyonudur. Tanımdan da anlaşıldığı gibi, bir parametre için minimal yeterli istatistiklerinin sınıfı, yeterli istatistiklerin sınıfını kapsar. Yani, herhangi bir parametre için yeterli istatistiklerden daha fazla minimal yeterli istatistik bulunabilir (Cacella ve Berger, 2002).

Faktörizasyon teoreminden yeterli istatistiği bulabiliyoruz. Minimal yeterli istatistiği bulmak için de aşağıdaki teorem kullanılabilir. Bu teoremin ispatı burada verilmemiştir (ispat için Casella ve Berger (2002) ye bakılabilir).

Teorem 7.2.1 X_1, X_2, \dots, X_n olasılık veya olasılık yoğunluk fonksiyonu $f(x; \theta)$ olan kitleden bir örneklem olsun. Eğer

$$\frac{f(\underline{x}; \theta)}{f(\underline{y}; \theta)} = g(x, y), \theta \text{ dan bağımsız} \Leftrightarrow T(\underline{x}) = T(\underline{y})$$

önermesi iki yönlü olarak sağlanıyorsa, T tahmin edicisi θ için minimal yeterlidir \diamond

Örnek 7.2.1 X_1, X_2, \dots, X_n beklenen değeri μ varyansı σ^2 olan normal dağılımdan bir örneklem olsun. Kolayca görüleceği gibi,

$$\begin{aligned} \frac{f(\underline{x}; \mu, \sigma^2)}{f(\underline{y}; \mu, \sigma^2)} &= \frac{\left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 + \frac{\mu}{\sigma^2} \sum_{i=1}^n x_i - \frac{n\mu^2}{2\sigma^2}\right]}{\left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n y_i^2 + \frac{\mu}{\sigma^2} \sum_{i=1}^n y_i - \frac{n\mu^2}{2\sigma^2}\right]} = \frac{\exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 + \frac{\mu}{\sigma^2} \sum_{i=1}^n x_i\right]}{\exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n y_i^2 + \frac{\mu}{\sigma^2} \sum_{i=1}^n y_i\right]} \\ &= \exp\left(-\frac{1}{2\sigma^2} \left[\sum_{i=1}^n x_i^2 - \sum_{i=1}^n y_i^2\right] + \frac{\mu}{\sigma^2} \left[\sum_{i=1}^n x_i - \sum_{i=1}^n y_i\right]\right) \end{aligned}$$

olup bu oranın parametrelerden (μ ve σ^2) bağımsız olabilmesi için gerek ve yeter koşul,

$$\sum_{i=1}^n x_i^2 = \sum_{i=1}^n y_i^2 \quad \text{ve} \quad \sum_{i=1}^n x_i = \sum_{i=1}^n y_i$$

olmasıdır. Yani, $T(\underline{x}) = \left(\sum_{i=1}^n x_i, \sum_{i=1}^n x_i^2\right)$ olmak üzere, $\frac{f(\underline{x}; \mu, \sigma^2)}{f(\underline{y}; \mu, \sigma^2)}$ oranı μ ve σ^2 den bağımsız

olması için gerek ve yeter koşul $T(\underline{x}) = T(\underline{y})$ olmasıdır. Teorem (7.2.1) e göre,

$T(\underline{X}) = \left(\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2\right)$ istatistiği (μ, σ^2) için minimal yeterlidir. Ayrıca,

$$T^*(\underline{X}) = \left(\frac{1}{n} \sum_{i=1}^n X_i, \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2\right) = (\bar{X}_n, S_n^2)$$

de (μ, σ^2) için minimal yeterlidir.

7.3. Yardımcı İstatistik (Ancillary Statistic)

Tanım 7.3.1 Dağılımı parametreye bağlı olmayan istatistiğe *yardımcı istatistik* (ancillary statistic) denir \otimes

Tanımdan da anlaşıldığı gibi, yardımcı istatistiğinin dağılımı parametreye bağlı olmadığından, yardımcı istatistiğe bağlı olarak parametre hakkında herhangi bir sonuç çıkarım yapılamaz. Ancak yardımcı istatistik başka bazı özellikler ile beraber kullanıldığında parametre hakkında önemli bilgiler elde edilir.

Örnek 7.3.1 Olasılık yoğunluk fonksiyonu $f(x; \theta)$ olan düzgün dağılımdan bir örneklem X_1, X_2, \dots, X_n olsun. Burada,

$$f(x; \theta) = \begin{cases} 1 & , \quad \theta < x < \theta + 1 \\ 0 & , \quad d.y. \end{cases}$$

olmak üzere, X lerin dağılım fonksiyonu,

$$F(x; \theta) = \begin{cases} 0 & , \quad x \leq \theta \\ x - \theta & , \quad \theta < x < \theta + 1 \\ 1 & , \quad x \geq \theta + 1 \end{cases}$$

şeklindedir. $\mathcal{R} = X_{(n)} - X_{(1)}$ örneklem uzunluğu istatistiğini gözönüne alalım. \mathcal{R} nin olasılık yoğunluk fonksiyonu için $X_{(1)}$ ve $X_{(n)}$ sıra istatistiklerinin ortak olasılık yoğunluk fonksiyonu,

$$g(x, y) = \begin{cases} n(n-1)(y-x)^{n-2} & , \quad \theta < x < y < \theta + 1 \\ 0 & , \quad d.y. \end{cases}$$

olup $\mathcal{R} = X_{(n)} - X_{(1)}$ nin olasılık yoğunluk fonksiyonu için $M = (X_{(1)} + X_{(n)})/2$ yardımcı dönüşümünü tanımlayalım. Ters dönüşümler, $X_{(1)} = (2M - \mathcal{R})/2$ ve $X_{(n)} = (2M + \mathcal{R})/2$ olup Jacobien matrisinin determinanı 1 dir. Dolayısı ile, \mathcal{R} ve M nin ortak olasılık yoğunluk fonksiyonu,

$$f_{\mathcal{R}, M}(r, m) = \begin{cases} n(n-1)r^{n-2} & , \quad 0 < r < 1, \theta + \frac{r}{2} < m < \theta + 1 - \frac{r}{2} \\ 0 & , \quad d.y. \end{cases}$$

olarak elde edilir. Ortak olasılık yoğunluk fonksiyonunun D_M üzerinden integrali

$$\int_{m=\theta+r/2}^{\theta+1-r/2} n(n-1)r^{n-2} dm = n(n-1)r^{n-2} ([\theta+1-r/2] - [\theta+r/2]) = n(n-1)r^{n-2}(1-r)$$

olup \mathcal{R} nin olasılık yoğunluk fonksiyonu,

$$f_{\mathcal{R}}(r) = \begin{cases} n(n-1)r^{n-2}(1-r) & , \quad 0 < r < 1 \\ 0 & , \quad d.y. \end{cases}$$

olarak bulunur. Görüldüğü gibi $\mathcal{R} = X_{(n)} - X_{(1)}$ nin dağılımı θ parametresine bağlı değildir. Yani, \mathcal{R} istatistiği θ için bir yardımcı istatistiktir. Benzer şekilde, $X_1, X_2, \dots, X_n \sim N(\mu, \sigma^2)$ dağılımından bir örneklem ise, $(n-1)S_n^2/\sigma^2 \sim \chi_{n-1}^2$ olup S_n^2 örneklem varyansının dağılımı μ ye bağlı değildir. Yani, S_n^2 istatistiği μ için bir yardımcı istatistiktir \oplus

7.4. Tamlık (Completeness)

Örnek (7.3.1) de $X_1, X_2, \dots, X_n \sim U(\theta, \theta + 1)$ örneklemini için $\mathcal{R} = X_{(n)} - X_{(1)}$ örneklem uzunluğu istatistiğinin bir yardımcı istatistik olduğunu gördük. Ayrıca, (\mathcal{R}, M) de θ için minimal

yeterli olup yardımcı istatistik, minimal yeterli istatistiğin önemli bir bileşenidir. Genellikle, yeterli istatistik ile yardımcı istatistik bağımsız değildir. Ancak, minimal yeterli istatistik aynı zamanda tam ise minimal yeterli istatistik ile yardımcı istatistik bağımsızdır (Teorem (7.4.2)).

Tanım 7.4.1 X_1, X_2, \dots, X_n olasılık veya olasılık yoğunluk fonksiyonu $f(x; \theta)$ olan kitleden bir örneklem, T de θ için yeterli olsun. Bütün θ lar için

$$E_{\theta}(g(T)) = 0 \Rightarrow P_{\theta}(g(T) = 0) = 1$$

önermesi sağlanıyorsa, T nin olasılık yoğunluk fonksiyonlarının ailesi *tamdır* denir \otimes

Buradaki, olasılık yoğunluk fonksiyonlarının ailesinin tamlığı yerine kısaca T tamdır diyeceğiz. Ayrıca tamlık, olasılık dağılımlarının ailesi için bir kavram olup özel dağılımlar için geçerli değildir. Örneğin, $X \sim N(0,1)$ ise, $g(x) = x$ için $E(g(X)) = 0$ olmasına rağmen $P(g(X) = 0) = 0$ dir. Ancak, $X \sim N(\theta,1)$ olsaydı, bütün θ lar için $E_{\theta}(g(X)) = 0$ olacak şekilde bir g fonksiyonu bulunamaz. Yani, $E_{\theta}(g(X)) = 0 \Rightarrow P_{\theta}(g(X) = 0) = 1$ önermesi sağlanır. Dolayısı ile, $X \sim N(\theta,1)$ dağılımlar ailesi tamdır.

Örnek 7.4.1 a) $X_1, X_2, \dots, X_n \sim Bern(p)$ olsun. $T = X_1 + X_2 + \dots + X_n$ tahmin edicisi p için yeterli ve $T \sim Binom(n, p)$ olduğunu biliyoruz. Şimdi, Binom dağılımlar ailesinin (yani T nin) tam olduğunu gösterelim. Bunun için, bütün p ler için $E_p(g(T)) = 0$ olsun. Buradan,

$$0 = E_p(g(T)) = \sum_{t=0}^n g(t) P_p(T=t) = \sum_{t=0}^n g(t) \binom{n}{t} p^t (1-p)^{n-t} = (1-p)^n \sum_{t=0}^n g(t) \binom{n}{t} \left(\frac{p}{1-p}\right)^t$$

bütün p ler için ($0 < p < 1$)

$$\sum_{t=0}^n g(t) \binom{n}{t} \left(\frac{p}{1-p}\right)^t = \sum_{t=0}^n g(t) \binom{n}{t} r^t = 0$$

olduğundan

$$E(g(T)) = 0 \text{ ise } \sum_{t=0}^n g(t) \binom{n}{t} r^t = 0$$

dır. $r = p/(1-p) > 0$ ve toplam içindeki bütün terimler pozitif olduğundan toplamın sıfır olması için bütün t ler için $g(t) = 0$ olması gerekir. Yani,

$$E_p(g(T) = 0) = 0 \Rightarrow P_p(g(T) = 0) = 1$$

önermesi doğrudur. Böylece, T istatistiği veya Bernoulli dağılımlar ailesinin tam olduğu söylenebilir.

b) X_1, X_2, \dots, X_n parametresi θ olan Poisson dağılımından bir örneklem olsun. $T = \sum_{i=1}^n X_i$

istatistiği θ için yeterli olup $T \sim \text{Poisson}(n\theta)$ dır. T nin olasılık fonksiyonu, $t = 0, 1, 2, 3, \dots$ için $g(t, \theta) = P_\theta(T = t) = e^{-n\theta} (n\theta)^t / t!$ şeklindedir. Bu şekildeki olasılık fonksiyonlarının ailesi $\mathcal{C} = \{g(t, \theta) : \theta > 0\}$ olsun. $E_\theta(h(T)) = 0$ olacak şekilde bir h fonksiyonu belirleyelim. T nin tam olduğunu göstermek için her t için $h(t) = 0$ olduğunun gösterilmesi gerekir. Dolayısı ile,

$$\begin{aligned} 0 = E_\theta(h(T)) &= \sum_{t=0}^{\infty} h(t) e^{-n\theta} (n\theta)^t / t! \\ &= e^{-n\theta} \left[h(0) + h(1) \frac{n\theta}{1} + h(2) \frac{(n\theta)^2}{2!} + h(3) \frac{(n\theta)^3}{3!} + \dots \right] \end{aligned}$$

olduğundan,

$$\left[h(0) + [nh(1)] \theta + \left[\frac{n^2}{2!} h(2) \right] \theta^2 + \left[\frac{n^3}{3!} h(3) \right] \theta^3 + \dots \right] = 0$$

yazılır. Bütün pozitif θ lar ($\theta > 0$) için toplamı sıfır olan herhangi bir serinin bütün katsayıları sıfırdır (Hogg ve Craig, 1995). Böylece, bütün pozitif θ lar için $h(t) = 0, \forall t$ yazılır. Buradan, $P_\theta(h(T) = 0) = 1$ olup $E_\theta(h(T) = 0) = 0 \Rightarrow P_\theta(h(T) = 0) = 1$ önermesi sağlanır. Yani, Poisson dağılımlar ailesi tamdır \oplus

Bir dağılımlar ailesinin veya istatistiğın tam olduğunun gösterilmesi bazen kolay olmayabilir. Bu dağılımlar ailesi aşağıda tanımı verilen bir üstel aile ise tahmin edicinin tam olduğu kolayca görülebilir. Üstel aileler beşinci bölümde kısaca incelenmişti. Tanım (5.4.1) deki üstel aile tanımına benzer bir tanım aşağıda verilmiştir.

Tanım 7.4.2 Olasılık veya olasılık yoğunluk fonksiyonlarının $\mathcal{G} = \{f(x; \theta) : \theta \in \Theta\}$ şeklindeki bir ailesi, her $f(x; \theta) \in \mathcal{G}$ için

$$f(x; \theta) = h(x) c(\theta) \exp(t(x) w(\theta))$$

şeklinde yazılabiliyorsa, $\mathcal{G} = \{f(x; \theta) : \theta \in \Theta\}$ ailesine bir *üstel aile* denir \otimes

Teorem 7.4.1 X_1, X_2, \dots, X_n üstel aile özelliğine sahip kitleden bir örneklem olsun. X lerin ortak olasılık veya olasılık yoğunluk fonksiyonu $f(x; \theta)$,

$$f(x; \theta) = h(x) c(\theta) \exp(t(x) w(\theta))$$

özelliğine sahip ise $T = \sum_{i=1}^n t(X_i)$ yeterli ve tamdır (Hogg ve Craig, 1995, sayfa 335) \diamond

Örnek 7.4.2 a) Bir önceki örnekte Bernoulli dağılımının parametresi için önerilen T nin tam olduğunu gördük. $T \sim Binom(n, p)$ olup olasılık fonksiyonu,

$$f(t; p) = P_p(T = t) = \binom{n}{t} p^t (1-p)^{n-t} = \binom{n}{t} (1-p)^n \left(\frac{p}{1-p}\right)^t = \binom{n}{t} (1-p)^n \exp\left(t \ln\left(\frac{p}{1-p}\right)\right)$$

olarak yazılabilir. Yani, $f(t; p)$ Binom olasılık fonksiyonlarının ailesi üsteldir. O halde Teorem (7.4.1) gereğince T yeterli ve tamdır.

Benzer şekilde Poisson dağılımlar ailesi de üstel olup tamdır. $T \sim Poisson(n\theta)$ olup T nin olasılık fonksiyonu

$$g(t, \theta) = P_\theta(T = t) = e^{-n\theta} (n\theta)^t / t! = n^t e^{-n\theta} \exp(\ln(\theta^t)) / t! = n^t e^{-n\theta} \exp(t \ln(\theta)) / t!$$

şeklinde yazılabilir. Böylece, $T = \sum_{i=1}^n X_i$ nin θ için yeterli ve tam olduğu söylenebilir.

$X_1, X_2, \dots, X_n \sim \text{Üstel}(\theta)$ olsun. X lerin olasılık yoğunluk fonksiyonu,

$$f(x; \theta) = \begin{cases} \frac{1}{\theta} e^{-x/\theta} & , x > 0 \\ 0 & , d.y. \end{cases}$$

olup $f(x; \theta) = \theta^{-1} \exp(-x/\theta)$ olduğundan üstel aile formunda yazılabilir. Dolayısı ile, $t(x) = x$ olmak üzere, $T = \sum_{i=1}^n X_i$ tahmin edicisi θ için yeterli ve tamdır.

b) Bazı olasılık yoğunluk fonksiyonları üstel aile formunda yazılamaz. Örneğin, $X_1, X_2, \dots, X_n \sim U(0, \theta)$ olsun. X lerin olasılık yoğunluk fonksiyonu,

$$f(x; \theta) = \theta^{-1} I_{(0 < x < \theta)}(x)$$

şeklinde olup, üstel aile formunda yazılamaz. Daha önce gösterildiği gibi, $X_{(n)}$ sıra istatistiği θ için yeterlidir (Örnek (7.1.2c)). Şimdi tam olduğunu gösterelim. Bunun için $T = X_{(n)}$ nin olasılık yoğunluk fonksiyonu $0 < t < \theta$ için $f(t; \theta) = n \theta^{-n} t^{n-1}$ olup, $E_\theta(g(T)) = 0$ olacak şekilde bir g fonksiyonu belirleyelim. $E_\theta(g(T)) = 0$ ise $\frac{d}{d\theta} E_\theta(g(T)) = 0$ olup çarpımın türevi kuralından

$$\frac{d}{d\theta} E_\theta(g(T)) = 0 \text{ ifadesi}$$

$$0 = E_{\theta}(g(T)) = \frac{d}{d\theta} E_{\theta}(g(T)) = \frac{d}{d\theta} \int_0^{\theta} g(t) f(t; \theta) dt = \frac{d}{d\theta} \int_0^{\theta} g(t) n \theta^{-n} t^{n-1} dt$$

$$= n \theta^{-n} \frac{d}{d\theta} \int_0^{\theta} g(t) t^{n-1} dt + \int_0^{\theta} g(t) t^{n-1} dt \left[\frac{d}{d\theta} (n \theta^{-n}) \right]$$

olarak yazılabilir. Diğer taraftan, $E_{\theta}(g(T)) = 0$ olduğundan $\int_0^{\theta} g(t) t^{n-1} dt = 0$ dır. Buradan da, son eşitliğin ikinci kısmı sıfır olup her θ için

$$0 = \frac{d}{d\theta} E_{\theta}(g(T)) = n \theta^{-n} \frac{d}{d\theta} \int_0^{\theta} g(t) t^{n-1} dt = n \theta^{-n} g(\theta) \theta^{n-1} = n \theta^{-1} g(\theta)$$

elde edilir. Yani, bütün pozitif θ ($\theta > 0$) lar için $E_{\theta}(g(T)) = 0$ ise $g(\theta) = 0$ dır. Buradan da, $P_{\theta}(g(T) = 0) = 1$ elde edilir. Yani, $T = X_{(n)}$ sıra istatistiği düzgün dağılımın θ parametresi için yeterli ve tamdır.

Benzer şekilde, X_1, X_2, \dots, X_n olasılık yoğunluk fonksiyonu $f(x; \theta)$ olan kitleden bir örneklem olsun. X lerin olasılık yoğunluk fonksiyonu,

$$f(x; \theta) = \begin{cases} e^{-(x-\theta)} & , x > \theta \\ 0 & , d.y \end{cases}$$

üstel aile formunda yazılamaz. Bu olasılık yoğunluk fonksiyonu $I_A(x)$ gösterge fonksiyonu ile $f(x; \theta) = e^{-(x-\theta)} I_{(x>\theta)}(x)$ şeklinde yazılabilir. Faktörizasyon teoreminden $T = X_{(1)}$ sıra istatistiği θ için yeterlidir.

Şimdi $X_{(1)}$ in tamlığını inceleyelim. Önce, T nin olasılık yoğunluk fonksiyonunun,

$$f_T(t; \theta) = \begin{cases} n e^{-n(t-\theta)} & , t > \theta \\ 0 & , d.y \end{cases}$$

şeklinde olduğunu belirtelim. $E_{\theta}(h(T)) = 0$ olacak şekilde bir h fonksiyonu belirlensin. Buradan, $E_{\theta}(h(T)) = 0$ ise $E_{\theta}(h(T))$ nin θ ya göre birinci türevi de sıfırdır. $E_{\theta}(h(T)) = 0$ olduğundan

$$\int_{\theta}^{\infty} h(t) e^{-nt} dt = 0 \text{ olup}$$

$$0 = \frac{d}{d\theta} E_{\theta}(h(T)) = \frac{d}{d\theta} \int_{\theta}^{\infty} h(t) n e^{-n(t-\theta)} dt = n \frac{d}{d\theta} \left[e^{n\theta} \int_{\theta}^{\infty} h(t) e^{-nt} dt \right]$$

$$= n \left[\frac{1}{n} e^{n\theta} \int_{\theta}^{\infty} h(t) e^{-nt} dt - e^{n\theta} h(\theta) e^{-n\theta} \right] = -\frac{1}{n} h(\theta)$$

bulunur. Buna göre, her θ için $h(\theta) = 0$ elde edilir. Yani, $P_\theta(h(T) = 0) = 1$ olup $T = X_{(1)}$ tamdır \oplus

Daha önce de bahsedildiği gibi, yardımcı istatistik tek başına parametre hakkında herhangi bir bilgi içermez. Ancak bu yardımcı istatistik, yeterli ve tam bir tahmin edici ile beraber kullanıldığında önemli istatistiki sonuçlara ulaşılır. Aşağıda ispatsız olarak verilen teorem bu söylenenleri özetlemektedir (ispat için Casella ve Berger (2002), sayfa 287 ye bakılabilir).

Teorem 7.4.2 (Basu Teoremi) T minimal yeterli ve tam ise, T herhangi bir yardımcı istatistikten bağımsızdır \diamond

Örnek 7.4.3 X_1, X_2, \dots, X_n beklenen değeri θ olan üstel dağılımdan bir örneklem olsun. Bu durumda, $T = X_1 + X_2 + \dots + X_n \sim \text{Gamma}(n, \theta)$ olduğunu biliyoruz. Ayrıca, T yeterli ve tamdır (üstel aile özelliğini sağlar). $Y = X_1 + \dots + X_{n-1} \sim \text{Gamma}(n-1, \theta)$ olup

$$U = \frac{X_n}{X_1 + X_2 + \dots + X_n} = \frac{X_n}{Y + X_n} \sim \text{Beta}(1, n-1)$$

olduğu da gösterilebilir. Yani, U yardımcı istatistik olup Basu teoremine göre U ile T bağımsızdır. Buna göre U nun beklenen değeri

$$\theta = E_\theta(X_n) = E_\theta(UT) = E_\theta(U)E_\theta(T) = (\theta n) E_\theta(U) \Rightarrow E_\theta(U) = n^{-1}$$

şeklinde kolayca hesaplanabilir.

Diğer taraftan, X_1, X_2, \dots, X_n beklenen değeri μ , varyansı σ^2 olan normal dağılımdan bir örneklem ise, \bar{X}_n örneklem ortalaması μ için yeterli ve tamdır (üstel aile özelliğini sağlar). Ayrıca, $(n-1)S_n^2 / \sigma^2 \sim \chi_{n-1}^2$ olduğunu (Teorem (6.3.1c) biliyoruz. Dolayısı ile S_n^2 nin dağılımı μ parametresine bağlı değildir. Yani, S_n^2 istatistiği μ için yardımcı istatistiktir. Basu teoremine göre de \bar{X}_n ile S_n^2 istatistikleri bağımsızdır. Daha önce, Teorem (6.3.1b) de \bar{X}_n ile S_n^2 nin bağımsız olduğu gösterildi. Oradaki ispat ile buradaki sonucu karşılaştırmamız \oplus