

## 1-2. STATISZTIKA GYAKORLAT: Rendezett minták

Az  $X_1, \dots, X_n$  fae mintából nyert  $X_1^* \leq \dots \leq X_n^*$  rendezett mintaelemek általában nem függetlenek és nem is azonos eloszlásúak. Bizonyos alapeloszlások esetén levezetjük eloszlásukat, ill. a differenciák eloszlását.

Olvassák el a tankönyvbéli anyagot  $X_k^*$  eloszlásfűről ( $F_{n;k}$ ) és sűrűségfű-éről, ha létezik ( $f_{n;k}$ ). Egyenletes alapeloszlás esetén pontosan tudjuk karakterizálni  $X_k^*$  eloszlását ( $k, n$ -től függő beta-eo), azonban a differenciák eloszlásához már az együttes eloszlásokra is szükség van. Ehhez is találhatók formulák a könyvben, melyek kiterjeszthetők tetszőleges abs.folyt. eloszlásokra.

1. Legyen  $X_1^* \leq \dots \leq X_n^*$  egy  $\mathcal{U}(0, 1)$  fae. mintából nyert rendezett minta. Határozzuk meg az

$$U_1 := X_1^*, \quad U_k := X_k^* - X_{k-1}^* \quad (k = 2, \dots, n), \quad U_{n+1} := 1 - X_n^*$$

differenciák eloszlását!

2. (Social distancing) Mi a valószínűsége, hogy  $n$  ember úgy helyezkedik el véletlenszerűen egy 1km-es szakaszon, hogy bármely kettőjük közti távolság legalább  $d$ . Itt  $0 < d \leq \frac{1}{n-1}$  adott konstans, pl.  $d = 2m$  COVID idején.
3. Legyen  $X_1^* \leq \dots \leq X_n^*$  egy  $\mathcal{Exp}(\lambda)$  fae. mintából nyert rendezett minta. Határozza meg az

$$U_1 := X_1^*, \quad U_k := X_k^* - X_{k-1}^* \quad (k = 2, \dots, n)$$

differenciák együttes és egyedi eloszlását is!

4. Legyen  $X_1^* \leq \dots \leq X_n^*$  egy  $\mathcal{Exp}(\lambda)$  fae. mintából nyert rendezett minta. Határozza meg  $X_k^*$  sfv-ét ( $k = 1, \dots, n$ )!
5. Legyen  $X_1^* \leq \dots \leq X_n^*$  egy  $\mathcal{Exp}(\lambda)$  fae. mintából nyert rendezett minta. Határozza meg  $X_k^*$  várható értékét és szórását ( $k = 1, \dots, n$ )!
6. Legyen  $X_1^* \leq \dots \leq X_n^*$  egy  $\mathcal{U}(0, 1)$  fae. mintából nyert rendezett minta. Határozza meg  $X_k^*$  tetszőleges momentumát!
7. Legyen  $X_1^* \leq \dots \leq X_n^*$  egy  $\mathcal{U}(0, 1)$  fae. mintából nyert rendezett minta. Határozza meg  $X_k^*$  varianciáját (szórásnégyzetét)! Hogyan változik ez  $k$ -val?
8. Legyen  $X_1^* \leq \dots \leq X_n^*$  egy  $\mathcal{U}(0, 1)$  fae. mintából nyert rendezett minta. Határozza meg  $X_i^*$  és  $X_j^*$  együttes eloszlását ( $1 \leq i < j \leq n$ )!
9. Legyen  $X_1^* \leq \dots \leq X_n^*$  egy  $\mathcal{U}(0, 1)$  fae. mintából nyert rendezett minta. Határozza meg  $X_i^*(1 - X_j^*)$  várható értékét ( $1 \leq i < j \leq n$ )!
10. Általánosítás az  $\mathcal{U}(0, \theta)$  és  $\mathcal{U}(-\theta, \theta)$  eloszlások rendezett mintáira.

## Megoldások

1. Kihasználjuk, hogy  $(0,1)$ -en egyenletes eloszlásnál egy intervallumba esés valószínűsége nem más, mint az intervallum hossza. Így

$$G_{n;1}(y) = \mathbb{P}(U_1 < y) = 1 - \mathbb{P}(X_1^* \geq y) = 1 - \prod_{i=1}^n \mathbb{P}(X_i \geq y) = 1 - (1-y)^n.$$

$$G_{n;n+1}(y) = \mathbb{P}(U_{n+1} < y) = \mathbb{P}(1 - X_n^* < y) = \mathbb{P}(X_n^* \geq 1-y) = 1 - \prod_{i=1}^n \mathbb{P}(X_i < 1-y) = 1 - (1-y)^n.$$

$k = 2, \dots, n$  esetén:

$$G_{n;k}(y) = \mathbb{P}(U_k < y) = 1 - \mathbb{P}(X_k^* - X_{k-1}^* \geq y) = 1 - (1-y)^n,$$

mivel ilyenkor az összes független mintaelem egy  $y$  hosszú intervallumon kívül helyezkedik el.

*Megjegyzés:*

- Tehát a differenciák azonos eloszlásúak, de nem függetlenek. Közös sfv-ük:

$$g_{n;k}(y) = G'_{n,k}(y) = n(1-y)^{n-1}, \quad k = 1, \dots, n+1.$$

Hogy nem függetlenek, az következik abból, hogy a sfv-ek szorzata nem ugyanaz, mint az együttes sűrűség, melyet a 3. feladat utáni megjegyzésben láthatunk.

- A megoldás geometriai valószínűségekkel (ld. Feller) és teljes indukcióval is kapható.
- $n \rightarrow \infty$  esetén, ha  $y = \frac{z}{n}$ , akkor

$$\lim_{n \rightarrow \infty} [1 - (1 - \frac{z}{n})^n] = 1 - e^{-z},$$

ami az exponenciális eloszlásfv. Ez azt jelenti, hogy a differenciák  $n$ -szerese aszimptotikusan 1 paraméterű, míg a differenciák aszimptotikusan  $n$  paraméterű ( $\frac{1}{n}$  várható értékű) exponenciális eloszlást követnek.

2. Kedvező esetben az  $X_1^* \leq \dots \leq X_n^*$  rendezett  $\mathcal{U}(0,1)$  fae. mintából nyert mintában a szomszédosak közt legalább  $d$  távolság van. Pl. az első ember kivételével mindenki visz egy  $d$  hosszúságú dárdát és azzal távol tartja az előtte levőt. Ez azt jelenti, hogy  $X_1, \dots, X_n$  egymástól függetlenül egy  $1 - (n-1)d$  hosszú szakaszon oszlik el, melynek valószínűsége  $[1 - (n-1)d]^n$ .
3. Egy analitikus és egy logikai megoldást is ismertetünk.

- $(X_1^*, \dots, X_n^*)$  együttes eloszlása (ld. tk.):

$$f(x_1, \dots, x_n) = n! \prod_{i=1}^n \lambda e^{-\lambda x_i} = n! \lambda^n e^{-\lambda \sum_{i=1}^n x_i}, \quad 0 \leq x_1 \leq x_2 \leq \dots \leq x_n.$$

Tudnunk kell, hogy a  $t : \mathbf{X} \rightarrow \mathbf{Y}$ , régi  $\rightarrow$  új,  $\mathbb{R}^n \rightarrow \mathbb{R}^n$  transzformáció invertálható  $t$  esetén  $\mathbf{X}$  sfv-ét ( $f(\mathbf{x})$ )  $\mathbf{Y}$  sfv-ébe ( $g(\mathbf{y})$ ) viszi át:

$$g(\mathbf{y}) = f(t^{-1}(\mathbf{y})) \left| \frac{\partial \mathbf{x}}{\partial \mathbf{y}} \right|, \quad (1)$$

ahol az utolsó tényező az inverz Jacobi mátrix nem-0 determinánsának abszolút értéke. Az inverz Jacobi mátrix  $ij$  eleme  $\frac{\partial x_i}{\partial y_j}$ .

Esetünkben az inverz transzformációt a következő koordinátáfv-ek írják le:

$$\begin{aligned} X_1^* &= U_1 \\ X_2^* &= U_1 + U_2 \\ &\vdots \\ X_n^* &= U_1 + U_2 + \dots + U_n. \end{aligned}$$

Az inverz Jacobi transzformáció mátrixa:

$$\begin{pmatrix} 1 & 0 & \dots & 0 \\ 1 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & \dots & 1 \end{pmatrix},$$

melynek determinánsa 1. Így  $U_1, \dots, U_n$  együttes sfv-e:

$$g(y_1, \dots, y_n) = n! \lambda^n e^{-\lambda \sum_{k=1}^n (n-k+1)y_k} \cdot 1 = \prod_{k=1}^n [(n-k+1)\lambda e^{-\lambda(n-k+1)y_k}].$$

Ebből látható, hogy  $U_1, \dots, U_n$  független, exponenciális eloszlásúak csökkenő paraméterrel:  $U_k \sim \text{Exp}((n-k+1)\lambda)$ ,  $k = 1, \dots, n$ .

- A másik mo az exp. eo örökifjúságát használja.

$$G_{n;1}(y) = \mathbb{P}(U_1 < y) = 1 - \mathbb{P}(X_1^* \geq y) = 1 - \prod_{i=1}^n (1 - F(y)) = 1 - [(1 - (1 - e^{-\lambda y}))^n] = 1 - e^{-n\lambda y},$$

azaz  $U_1 \sim \text{Exp}(n\lambda)$ .

Gondoljuk azt, hogy 0 időtől  $n$  örökifjú élettartamú izzólámpát üzemeltetünk párhuzamosan. Ekkor  $U_1 = X_1^*$  a leghamarabb kiégő izzó élettartama. A többi  $n-1$  izzó ezután függetlenül üzemel ugyanolyan esélyekkel. A közülük leghamarabb kiégő élettartama ettől számítva

$$U_2 = X_2^* - X_1^* \sim \text{Exp}((n-1)\lambda)$$

a fentiek szerint és független  $U_1$ -től, s.í.t, a  $k$ -adiknak kiégő izzó élettartama

$$U_k = X_k^* - X_{k-1}^* \sim \text{Exp}((n-k+1)\lambda),$$

és független  $U_1, \dots, U_{k-1}$ -től,  $k = 2, \dots, n$ .

*Megjegyzés:*

- Tehát a differenciák függetlenek, de nem azonos eloszlásúak.

- A fenti (1) képlettel, az 1. feladatbeli  $\mathcal{U}(0,1)$  rendezett mintából nyert differenciák együttes sfv-e:

$$g(y_1, \dots, y_n) = n! \cdot 1 \cdot 1 = n!,$$

ami konstans, ellentétben az 1. feladat megjegyzésében látható  $g_{n;k}$  sfv-ek szorzatával. Tehát a differenciák ott nem függetlenek (már csak azért sem, mert összegük 1, de az első  $n$  sem független).

4. A tanult trnszformációs képlettel  $X_k^*$  sfv-e a  $(0,1)$ -en egyenletes  $k$ -adik rendezett mintaelem beta-sfv-ébe helyettesítve az exponenciális elozlás- és sfv-t kapható:

$$f_{n;k}(x) = n \binom{n-1}{k-1} (1 - e^{-\lambda x})^{k-1} \cdot (e^{-\lambda x})^{n-k} \cdot \lambda e^{-\lambda x},$$

$k = 1, \dots, n$ , ha  $x > 0$  és 0 különben.

5. Mivel  $X_k^* = \sum_{i=1}^k U_i$  függetlenek összege:

$$\mathbb{E}(X_k^*) = \sum_{i=1}^k \frac{1}{(n-k+1)\lambda} = \frac{1}{\lambda} \sum_{i=1}^k \frac{1}{n-k+1}, \quad k = 1, \dots, n$$

és

$$\mathbb{D}^2(X_k^*) = \sum_{i=1}^k \frac{1}{(n-k+1)^2 \lambda^2} = \frac{1}{\lambda^2} \sum_{i=1}^k \frac{1}{(n-k+1)^2}, \quad k = 1, \dots, n.$$

$\mathbb{D}(X_k^*)$  ennek gyöke.

*Megjegyzés:*  $n \rightarrow \infty$  esetén az  $\mathbb{E}(X_n^*)$ -t definiáló sor nem konvergens ( $\ln n$  nagyságrendű), míg a  $\mathbb{D}^2(X_n^*)$ -t definiáló sor konvergens ( $\pi$ -től függő összeggel).

6. Mivel  $X_k^* \sim \text{Beta}(k, n-k+1)$ , ezért

$$\begin{aligned} \mathbb{E}(X_k^*)^s &= n \binom{n-1}{k-1} \int_0^1 u^s u^{k-1} (1-u)^{n-k} du = n \binom{n-1}{k-1} \int_0^1 u^{s+k-1} (1-u)^{(n+s)-(s+k)} du \\ &= \frac{n \binom{n-1}{k-1}}{(n+s) \binom{n+s-1}{s+k-1}} = \frac{\binom{s+k-1}{s}}{\binom{n+s}{s}}, \quad k = 1, \dots, n; \quad s = 1, 2, \dots \end{aligned}$$

7. Következésképp

$$\begin{aligned} \mathbb{E}(X_k^*) &= \frac{k}{n+1} \\ \mathbb{E}(X_k^*)^2 &= \frac{k(k+1)}{(n+1)(n+2)} \\ \mathbb{D}^2(X_k^*) &= \mathbb{E}(X_k^*)^2 - \mathbb{E}^2(X_k^*) = \frac{k(n-k+1)}{(n+1)^2(n+2)} \quad (k = 1, \dots, n). \end{aligned}$$

Ebből látható, hogy

$$\mathbb{D}^2(X_k^*) = \mathbb{D}^2(X_{n-k+1}^*), \quad 1 \leq k \leq \frac{n}{2},$$

és a szimmetrikus szórásnégyzetek növekednek  $k$ -val (a fenti számláló folytonos megfelelője az  $x(n-x)$  fv, melynek maximuma  $\frac{n}{2}$ -ben van).

8. Legyen  $X_1^* \leq \dots \leq X_n^*$  egy  $\mathcal{U}(0, 1)$  fae. mintából nyert rendezett minta.  $1 \leq i < j \leq n$  indexekre  $X_i^*$  és  $X_j^*$  együttes sfv-e az  $r = 2$ ,  $k_1 = i$ ,  $k_2 = j$  szereposztásban:

$$g_{n;i,j}(x, y) = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} x^{i-1} (y-x)^{j-i-1} (1-y)^{n-j}, \quad 0 \leq x \leq y \leq 1.$$

9. Ezzel

$$\begin{aligned} \mathbb{E}(X_i^*(1 - X_j^*)) &= \int_0^1 \int_0^y x(1-y)g_{n;i,j}(x, y) dx dy = \\ &= \frac{n!}{(i-1)!(j-i-1)!(n-j)!} \int_0^1 \int_0^y x^i (y-x)^{j-i-1} (1-y)^{n-j+1} dx dy = \\ &= \frac{n!}{(i-1)!(j-i-1)!(n-j)!} \cdot \frac{(n+2)!}{i!(j-i-1)!(n-j+1)!} \int_0^1 \int_0^y g_{n+2;i+1,j+1}(x, y) dx dy = \\ &= \frac{n!}{(i-1)!(j-i-1)!(n-j)!} \cdot \frac{i!(j-i-1)!(n-j+1)!}{(n+2)!} = \frac{i(n-j+1)}{(n+1)(n+2)}. \end{aligned}$$

A poén az volt, hogy a második sorbeli sűrűség egy  $g_{n+2;i+1,j+1}(x, y)$  sűrűség 'érdemi része' volt, a normáló tényező nélkül. Így integrálja (a tartón) a normáló tényező reciproka.

Ebből  $\mathbb{E}(X_i^* X_j^*)$ , továbbá  $X_i^*$  és  $X_j^*$  kovarianciája is kiszámolható.

10. A mondottak alkalmazhatók az  $X \sim \mathcal{U}(0, \theta)$  eloszlásra az  $Y = \frac{X}{\theta} \sim \mathcal{U}(0, 1)$  és az  $X \sim \mathcal{U}(-\theta, \theta)$  eloszlásra az  $Y = \frac{X+\theta}{2\theta} \sim \mathcal{U}(0, 1)$  lineáris transzformációkkal.