

Valószínűségszámítás és statisztika előadás informatika BSC/B szakosoknak



2021/2022 2. félév

Zempléni András


andras.zempleni@ttk.elte.hu

<http://zempleni.elte.hu>

Függvény várható értéke

- Legyen $g: \mathbf{R} \rightarrow \mathbf{R}$ függvény, X diszkrét valószínűségi változó, $p_i = P(X=x_i)$. Ekkor $g(X)$ is valószínűségi változó, a várható értéke $E(g(X))$ az eredeti X változó eloszlásából is kiszámolható:

$$E(g(X)) = p_1 g(x_1) + p_2 g(x_2) + \dots$$





Összeg várható értéke

- X, Y tetszőleges, véges várható értékűek. Ekkor $E(X+Y) = E(X) + E(Y)$. Bizonyítás a diszkrét esetre:

$$E(X+Y) = \sum_{k,m} (x_k + y_m)P(X = x_k, Y = y_m) = \sum_{k,m} x_k P(X = x_k, Y = y_m) +$$
$$+ \sum_{k,m} y_m P(X = x_k, Y = y_m) = \sum_k x_k P(X = x_k) + \sum_m y_m P(Y = y_m) = E(X) + E(Y).$$

- Indukcióval: $E(X_1 + X_2 + \dots + X_n) = E(X_1) + E(X_2) + \dots + E(X_n)$.



Alkalmazások

- A binomiális eloszlás várható értéke:
 $X = X_1 + X_2 \dots + X_n$ ahol X_i az i -edik kísérletnél az A esemény indikátora.
- Az előző tulajdonság alapján
$$E(X) = E(X_1 + X_2 \dots + X_n) = n \cdot E(X_1) = n \cdot p.$$
- Ugyanígy a hipergeometrikus eloszlás várható értéke is $n \cdot p$ ($p = M/N$ a selejtarány).



Névjegy probléma

- n ember bedobja a névjegyét egy kalapba, ezután mindenki húz egyet véletlenszerűen. X : azon személyek száma, akik a saját névjegyüket húzzák.
- X_i : az i -edik ember a saját névjegyét húzza.
 $E(X_i) = P(X_i = 1) = 1/n$.
- $X = X_1 + X_2 + \dots + X_n$ és így a várható érték additivitása alapján
 $E(X) = E(X_1 + X_2 + \dots + X_n) = n \cdot E(X_1) = n \cdot 1/n = 1$.
- Szimuláció

Valószínűségi változók szórásnégyzete

- Nem mindegy, hogy mekkora a vizsgált véletlen mennyiség ingadozása.
- Jobb, ha a buszok pontosan 10 percenként jönnek, mintha időnként 3 jön egymás után, és aztán 30 percet kell várni.
- Az ingadozás számszerűsítése: a várható értéktől vett átlagos négyzetes eltérés, elnevezése: szórásnégyzet. Formálisan:

$$D^2(X) := E[(X - E(X))^2].$$

- Kiszámítása: $D^2(X) = E[X^2 - 2XE(X) + E^2(X)] =$
 $= E(X^2) - 2E(X)E(X) + E^2(X)$
a várható érték linearitása miatt. Azaz

$$D^2(X) = E(X^2) - E^2(X).$$



Tulajdonságok

- $D^2(X) \geq 0$, mert nemnegatív valószínűségi változó várható értéke.
- $D^2(aX+b) = a^2 D^2(X)$, mert $D^2(aX+b) = E[(aX+b - E(aX+b))^2] = E[(aX+b - aE(X) - b)^2] = E[(aX - aE(X))^2] = a^2 E[(X - E(X))^2]$.
- Abból, hogy $E(X)$ véges, még nem következik $D^2(X)$ végeessége, hiszen ha $P(X=k) = c/k^3$ (egyértelműen megadható olyan c , amire ez eloszlás lesz) akkor $E(X)$ véges, de $E(X^2) = c(1 + 1/2 + \dots + 1/k + \dots)$, ami végtelen.



Példák

- Az elfajult eloszlás szórásnégyzete:

$$D^2(X) = E(X^2) - E^2(X) = c^2 - c^2 = 0.$$

- Megfordítás: ha $D^2(X) = 0$, akkor X 1 valószínűséggel konstans.

Biz.: $(X - E(X))^2 \geq 0$, várható értéke 0, tehát ő maga is 1 valószínűséggel 0, azaz $X = E(X)$ 1 valószínűséggel.

- A p valószínűségű A esemény indikátorának szórásnégyzete:

$D^2(X) = E(X^2) - E^2(X) = p - p^2 = p(1-p)$. Azaz $p=0.5$ esetén a legnagyobb a szórásnégyzet.

- A kockadobás szórásnégyzete:

$$D^2(X) = E(X^2) - E^2(X) = (1+4+\dots+36)/6 - 49/4 = 91/6 - 49/4 \\ = (182-147)/12 = 35/12.$$

Példák/2

A Poisson eloszlás szórásnégyzete:

$$\begin{aligned} E(X^2) &= \sum_{k=1}^{\infty} k^2 \lambda^k \frac{e^{-\lambda}}{k!} = \sum_{k=1}^{\infty} k \lambda^k \frac{e^{-\lambda}}{(k-1)!} = \lambda \sum_{k=1}^{\infty} (k-1+1) \lambda^{k-1} \frac{e^{-\lambda}}{(k-1)!} \\ &= \lambda^2 \sum_{k=2}^{\infty} \lambda^{k-2} \frac{e^{-\lambda}}{(k-2)!} + \lambda = \lambda^2 + \lambda. \end{aligned}$$

Ebből

$$D^2(X) = \lambda^2 + \lambda - \lambda^2 = \lambda.$$

Azaz a Poisson eloszlás várható értéke és szórásnégyzete megegyezik, ezt például a statisztikai alkalmazásoknál is lehet használni.



A szórás

- Szórásnégyzet mértékegysége az eredeti X mértékegységének a négyzete (azaz pl. a buszok követési időközénél négyzetperc). Ez nem teszi egyszerűvé interpretációját.
- Szórás: $D(X)$ a szórásnégyzet pozitív négyzetgyöke. Ez már a megfelelő mértékegységű, $D(aX) = |a|D(X)$.



Összeg szórásnégyzete

- $D^2(X+Y) = E[(X+Y-E(X+Y))^2] =$
 $E[(X-E(X)+Y-E(Y))^2] = E[(X-E(X))^2] + E[(Y-E(Y))^2] +$
 $+ 2E[(X-E(X))(Y-E(Y))] = D^2(X) + D^2(Y) +$
 $+ 2E[(X-E(X))(Y-E(Y))]$

- Példák (legyen X 0-ra szimmetrikus eloszlás):

- $X=Y$ esetén $D^2(X+Y) = D^2(2X) = 4 D^2(X)$
- $X=-Y$ esetén $D^2(X+Y) = D^2(X-X) = D^2(0) = 0$

azaz nem csak X és Y egydimenziós eloszlásától, hanem az együttes viselkedésüktől, azaz az együttes eloszlásuktól is függ az összegük szórásnégyzete.



A független val. változók esete

- *Állítás.* ha X, Y függetlenek, akkor $E(XY) = E(X)E(Y)$.

- *Bizonyítás.*

$$E(XY) = \sum_{k,m} x_k y_m P(X = x_k, Y = y_m)$$

ami a függetlenség miatt így írható:

$$= \sum_k x_k P(X = x_k) \sum_m y_m P(Y = y_m) = E(X)E(Y).$$



Kovariancia

- Definíció. Az X és Y kovarianciája:
$$\text{cov}(X, Y) := E[(X - E(X))(Y - E(Y))]$$
- Kiszámítása: $\text{cov}(X, Y) = E[XY - XE(Y) - YE(X) + E(X)E(Y)] = E(XY) - E(X)E(Y)$
- Az előzőek értelmében $\text{cov}(X, Y) = 0$, ha X és Y függetlenek.
- Megj.: Abból, hogy $\text{cov}(X, Y) = 0$ nem következik, hogy függetlenek: legyen X szimmetrikus a $0 = r_a$ (pl. $P(X=1) = P(X=-1) = P(X=0) = 1/3$) és $Y = X^2$. Ekkor $\text{cov}(X, Y) = E(X^3) - E(X)E(X^2) = 0 - 0$, hiszen $E(X^3) = E(X) = 0$.
- A kovariancia szimmetrikus: $\text{cov}(X, Y) = \text{cov}(Y, X)$
- $\text{cov}(X, X) = D^2(X)$



Korrelációs együttható

- A kovariancia skálafüggő: $\text{cov}(aX, bY) = ab \cdot \text{cov}(X, Y)$
- A változók közötti lineáris kapcsolat erősségét mérő mennyiség a *korrelációs együttható*:

$$R(X, Y) = \frac{\text{cov}(X, Y)}{D(X)D(Y)}$$

- Tulajdonságai:
 - $R(X, Y) = 0$, ha X és Y függetlenek (ez sem fordítható meg)
 - Ez alapján definíció szerint legyen $R(X, Y) = 0$, ha X vagy Y elfajult eloszlású.
 - $R(X, aX + b) = 1$, ha $a > 0$, mert $\text{cov}(X, aX + b) = aD^2(X)$.

A korreláció tulajdonságai

Állítás: $|R(X,Y)| \leq 1$ és $|R|=1$ akkor és csak akkor, ha $X=aY+b$ 1 valószínűséggel ($a \neq 0, b \in \mathbf{R}$).

- Ehhez:

$$X^* = \frac{X - E(X)}{D(X)}, Y^* = \frac{Y - E(Y)}{D(Y)}$$

az úgynevezett standardizált változók. $E(X^*)=E(Y^*)=0$,
 $D(X^*)=D(Y^*)=1$. $R(X,Y)=E(X^*Y^*)$.

$0 \leq E(X^* \pm Y^*)^2 = E(X^{*2}) \pm 2E(X^*Y^*) + E(Y^{*2}) = 2 \pm 2E(X^*Y^*)$, tehát
 $|R(X,Y)| \leq 1$.

Ebből:

- $R=1$ akkor és csak akkor, ha $0=E(X^*-Y^*)^2$, azaz $X^*=Y^*$ valószínűséggel. Ekkor $X=aY+b$, $a>0$.
- $R=-1$ akkor és csak akkor, ha $0=E(X^*+Y^*)^2$, azaz $X^*=-Y^*$ 1 valószínűséggel. Ekkor $X=aY+b$, $a<0$.



Negatív binomiális eloszlás

- Legyen $X = X_1 + X_2 + \dots + X_r$, ahol X_i p paraméterű Pascal eloszlású változó, függetlenek. Ekkor X eloszlása:

$$P(X = k) = \binom{k-1}{r-1} p^r (1-p)^{k-r}$$

ha $k \geq r$ (különben 0). Elnevezés: r -ed rendű, p paraméterű negatív binomiális eloszlás. Ez éppen annak a kísérletnek a sorszáma, ahol az r -edik sikeres jön ki.

A negatív binomiális eloszlás