

Matematika A4
Feladatok a Tematika 9. és 11. pontjához
 Szabados Tamás kurzusa / Balázs Márton gyakorlata

Feltételes várható érték

Adott két valószínűségi változó, X és Y . Az X -nek $Y = y$ feltételre vett feltételes várható értéke

$$\mathbb{E}(X | Y = y) = \begin{cases} \sum_i x_i \cdot \mathbb{P}\{X = x_i | Y = y\}, & \text{ha } X \text{ diszkrét,} \\ \int_{-\infty}^{\infty} x \cdot f(x | Y = y) dx, & \text{ha } X \text{ folytonos.} \end{cases}$$

Mint ahogy a feltételes valószínűség egy szabályos valószínűség (tudja az axiómákat), a feltételes várható érték is egy szabályos várható érték, tehát minden tulajdonság, ami a várható értékre igaz volt, a feltételes várható értékre is igaz lesz (pl. linearitás). A feltételes súlyfüggvény illetve sűrűségfüggvény definíciója alapján könnyen ellenőrizhető, hogy a diszkrét illetve folytonos esetben

$$\begin{aligned} \sum_j \mathbb{E}(X | Y = y_j) \cdot \mathbb{P}\{Y = y_j\} &= \sum_{i,j} x_i \cdot \mathbb{P}\{X = x_i | Y = y_j\} \cdot \mathbb{P}\{Y = y_j\} = \sum_{i,j} x_i \cdot \mathbb{P}\{X = x_i, Y = y_j\} \\ &= \mathbb{E}(X), \end{aligned}$$

illetve

$$\int_{-\infty}^{\infty} \mathbb{E}(X | Y = y) \cdot g(y) dy = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x \cdot f(x | Y = y) \cdot g(y) dx dy = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x \cdot h(x, y) dx dy = \mathbb{E}(X).$$

Ezt elegánsabban és rövidebben úgy is írhatjuk, hogy $\mathbb{E}[\mathbb{E}(X | Y)] = \mathbb{E}(X)$, amit *toronyszabálynak* nevezünk. Itt $\mathbb{E}(X | Y)$ az Y függvénye, és ezért maga is egy valószínűségi változó. Y -tól ugyanúgy függ, mint ahogy $\mathbb{E}(X | Y = y)$ függ y -től.

1. X és Y közös sűrűségfüggvénye

$$h(x, y) = \frac{1}{y} \cdot e^{-(y+x/y)}, \quad \text{ha } x > 0, y > 0.$$

- (a) Mutassuk meg, hogy Y peremeloszlása exponenciális(1).
 - (b) Mutassuk meg, hogy az $(X | Y = y)$ eloszlás, azaz X feltételes eloszlása az $Y = y$ feltétel mellett exponenciális(1/y).
 - (c) Használjuk az előbbi két pontot $\mathbb{E}(X)$ és $\mathbb{E}(Y)$ meghatározására. Bátrabbak ellenőrizhetik, hogy $\mathbf{Cov}(X, Y) = 1$, miután belátták a fentiekhez hasonlóan, hogy $\mathbb{E}(X \cdot Y | Y) = Y \cdot \mathbb{E}(X | Y)$, és $\mathbb{E}(X \cdot Y) = \mathbb{E}[\mathbb{E}(X \cdot Y | Y)] = \mathbb{E}[Y \cdot \mathbb{E}(X | Y)]$.
2. Egy bányász a bánya egy termében rekedt. A teremről három ajtó nyílik: az első ajtó 3 órányi út végén a szabadba vezet. A második ajtó egy alagútba nyílik, mely 5 órányi séta után visszavezet ugyanebbe a terembe. A harmadik ajtó szintén egy alagútba nyílik, mely 7 órányi séta után vezet vissza ugyanebbe a terembe. A bányász minden alkalommal amikor ebbe a terembe ér, e három ajtó közül választ egyet egyenlő valószínűséggel, az előző választásoktól függetlenül. Legyen X a szabadba kijutáshoz szükséges idő, Y pedig a legelső alkalommal kiválasztott ajtó sorszáma. Érveljünk amellet, hogy $\mathbb{E}(X | Y = 1) = 3$, $\mathbb{E}(X | Y = 2) = 5 + \mathbb{E}(X)$, és $\mathbb{E}(X | Y = 3) = 7 + \mathbb{E}(X)$. Alkalmazzunk egy toronyszabályt ezen feltételes várható értékekkel, és így mutassuk meg, hogy $\mathbb{E}(X) = 15$.
 3. Legyenek X_1, X_2, \dots, X_n független és azonos eloszlású valószínűségi változók. Határozzuk meg

$$\mathbb{E}(X_1 | X_1 + X_2 + \dots + X_n = x)$$

értékét. Segítség: tudjuk, hogy $\mathbb{E}(X_1 + X_2 + \dots + X_n | X_1 + X_2 + \dots + X_n = x)$ mivel egyenlő, ezután már csak a feltételes várható érték additivitását kell használnunk, és azt, hogy a változók azonos eloszlásúak.

Kétdimenziós normális eloszlás

A kétdimenziós normális eloszlás sűrűségfüggvénye

$$h(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \cdot \exp\left\{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x-\mu_x}{\sigma_x}\right)^2 + \left(\frac{y-\mu_y}{\sigma_y}\right)^2 - 2\rho\frac{(x-\mu_x)(y-\mu_y)}{\sigma_x\sigma_y}\right]\right\}.$$

Az ilyen sűrűségfüggvényt követő (X, Y) pár esetén X peremeloszlása $\mathcal{N}(\mu_x, \sigma_x^2)$, Y peremeloszlása $\mathcal{N}(\mu_y, \sigma_y^2)$, és a köztük korrelációja ρ .

1. Mutassuk meg, hogy ha (X, Y) eloszlása kétdimenziós normális, akkor
 - (a) X feltételes eloszlása az $Y = y$ feltétel mellett normális, $\mu_x + \rho\frac{\sigma_x}{\sigma_y}(y - \mu_y)$ várható értékkel, és $\sigma_x^2(1 - \rho^2)$ szórásnégyzettel. (Ez egy kicsit számolás, de egy ügyes változócsere sokat segít.)
 - (b) X és Y korrelációja ρ .
 - (c) X és Y független akkor és csak akkor, ha $\rho = 0$.
2. Íme hogyan lehet egy általános kétdimenziós normális eloszlást független normálisak összegére bontani. Rögzítsünk $\sigma_x, \sigma_y > 0$, $\mu_x, \mu_y \in \mathbb{R}$, és $-1 < \rho < 1$ paramétereket. Legyen Y egy normális eloszlású valószínűségi változó μ_y várható értékkel és σ_y szórással. Legyen Z egy másik, Y -től független normális valószínűségi változó, $\mu_x - \rho \cdot \mu_y \cdot \frac{\sigma_x}{\sigma_y}$ várható értékkel és $(1 - \rho^2) \cdot \sigma_x^2$ szórásnégyzettel. Definiáljuk az $X := \rho \cdot \frac{\sigma_x}{\sigma_y} \cdot Y + Z$ változót. Mutassuk meg, hogy az (X, Y) pár eloszlása kétdimenziós normális, a megfelelő μ_x és μ_y várható értékekkel, σ_x és σ_y szórással, és ρ korrelációval.
3. Legyen X standard normális eloszlású, és I X -től független, $\mathbb{P}\{I = 1\} = \mathbb{P}\{I = 0\} = 1/2$ eloszlással. Definiáljuk a következő valószínűségi változót:

$$Y := \begin{cases} X & , \text{ ha } I = 1, \\ -X & , \text{ ha } I = 0. \end{cases}$$

Azaz: Y (X -től független) egyenlő eséllyel lesz X vagy $-X$.

- (a) Független-e X és Y ?
 - (b) Független-e I és Y ?
 - (c) Mutassuk meg, hogy Y standard normális eloszlású.
 - (d) Mutassuk meg, hogy $\mathbf{Cov}(X, Y) = 0$.
4. Legyenek X és Y független standard normális valószínűségi változók, és $U := (X + Y)/\sqrt{2}$, $V := (X - Y)/\sqrt{2}$. Mutassuk meg, hogy U és V szintén független standard normális változók.

Általános regresszió

Adott az (X, Y) kétdimenziós valószínűségi változó az együttes eloszlásával (például folytonos esetben sűrűségfüggvényével). X -et megfigyelve Y -t szeretnénk közelíteni egy $k(X)$ alakú tippelő függvénnyel. A közelítés azt jelenti, hogy az elkövetett $(Y - k(X))^2$ négyzetes hiba átlagát szeretnénk minimalizálni. Pontosabban azt a k függvényt keressük, amire $\mathbb{E}(Y - k(X))^2$ minimális. Az órán tanult tétel kimondja, hogy ebben az esetben a megoldás a feltételes várható érték: $k(x) = \mathbb{E}(Y | X = x)$. Ha pedig az elkövetett abszolút hiba átlagát, azaz $\mathbb{E}(|Y - k(X)|)$ -et szeretnénk minimalizálni, akkor a lehető legjobb tippelés az Y feltételes mediánja. Azaz ebben az esetben az $F_{Y|X}(y | X = x) = \int_{-\infty}^y g(v | X = x) dv$ feltételes eloszlásfüggvényt kell 1/2-del egyenlővé tenni, és belőle y -t, mint x függvényét kifejezni.

1. A Duna holnaputáni budapesti vízállását akadjuk becsülni a mai bécsi vízállásból. Bár a két vízállás közt szoros kapcsolat van, azért pontosan nem lehet megmondani a vízállást, mindkettőt egy-egy valószínűségi változó írja le. Tegyük fel, hogy mindkét vízállást egy 0 és 1 közti számmal tudjuk jellemezni, melynek legyen az együttes sűrűségfüggvénye $h(x, y) = \frac{6}{5} \cdot (x + (y - 1)^2)$, ha $0 < x < 1$ és $0 < y < 1$.
 - (a) Határozzuk meg a budapesti vízállás eloszlását a bécsi ismeretében, azaz a feltételes sűrűségfüggvényt.
 - (b) Mi annak a valószínűsége, hogy Budapesten alacsonynak nevezhető (azaz 0 és 1/2 közé esik) a vízállás, ha Bécsben x volt? (Mennyi ez $x = 1/3$ -ra?)

- (c) Ha már ismerjük a bécsi vízállást, mire tippelünk a budapestire, ha a lehető legkisebb átlagos négyzetes hibát akarjuk elkövetni?
- (d) És ha az átlagos abszolút hibát akarjuk minimalizálni?
2. $X = \text{RND1}$, $Y = \text{RND1} \cdot \text{RND2}$ eloszlás esetén láttuk, hogy az együttes sűrűségfüggvény $h(x, y) = 1/x$, ha a $0 < y < x < 1$ háromszögön vagyunk. Mi a regressziós görbe, ha az abszolút hibát, illetve ha a négyzetes hibát szeretnénk minimalizálni?
3. Az egységkörön választunk egyenletes eloszlás szerint egy (X, Y) pontot. Az X koordináta ismeretében hogyan közelítenénk $|Y|$ -t, feltéve, hogy a hiba abszolútértékénél szeretnénk minimalizálni?
4. Többpártrendszer esetén az egyes pártokra leadott szavazatok százalékos aránya valószínűségi változó. A Zöldek az összes szavazatok X , a Demokraták az összes szavazatok Y hányadát kapják, együttes eloszlásuk a $h(x, y) = 24xy$, ha $0 < x$, $0 < y$, $x + y < 1$ sűrűségfüggvényt követi. Ha a Demokraták az összes szavazatok 40%-át kapták, mire tippelünk, mennyit kaptak a Zöldek?
5. Legyen (X, Y) egyenletes eloszlású a $(0, 0)$, $(1, 0)$, $(0, 2)$ pontok által meghatározott háromszögön. Számítsuk ki Y -nak X -re vonatkozó regressziós függvényét.
6. Magyarországon a 18 év feletti férfiak testmagasságának átlagos értéke 178 cm, szórása 10 cm. Nőknél ugyanezek az adatok 166 cm és 8cm. Focimeccseken a drukkerok 10%-a nő, a többiek férfiak. Mindkét nem testmagasságának eloszlását normálisnak véve:
- (a) Mi annak a valószínűsége, hogy egy 170 cm-nél alacsonyabb szurkoló nő?
- (b) Adjuk meg x függvényében annak a valószínűségét, hogy egy x cm magas drukker férfi.
- (c) Hogyan tippeljünk a szurkolók testmagasságából a nemükre, ha a célunk az, hogy a lehető legnagyobb valószínűséggel helyesen tippeljünk?

Lineáris regresszió

A gyakorlatban gyakran nem tudjuk az együttes sűrűségfüggvényt meghatározni. Ilyenkor könnyebb lehet a várható értéket, a szórást, a kovarianciát kiszámolni. Ezek segítségével már meg tudjuk mondani, hogy melyik az a lineáris függvény, amivel tippelve a hiba négyzetének várható értéke a legkisebb.

$$y - \mathbb{E}(Y) = \frac{\text{Cov}(X, Y)}{\mathbb{D}^2(X)} \cdot (x - \mathbb{E}(X)).$$

Ez egy kicsit másképp:

$$\frac{y - \mathbb{E}(Y)}{\mathbb{D}(Y)} = \varrho(X, Y) \cdot \frac{x - \mathbb{E}(X)}{\mathbb{D}(X)},$$

ahol $\varrho(X, Y) = \frac{\text{Cov}(X, Y)}{\mathbb{D}(X)\mathbb{D}(Y)}$ az X és Y korrelációs együtthatója. Ha $\varrho(X, Y) = \pm 1$, akkor a két valószínűségi változó közt lineáris függés van. Ha $\varrho(X, Y) = 0$, akkor a változók *korrelálatlanok* (ami nem szükségképpen jelenti azt, hogy függetlenek volnának).

1. Egy kétdimenziós valószínűségi változó sűrűségfüggvénye $\frac{1}{6}xy$ ($0 < x < 2$, $x < y < 2x$). Milyen $k(y)$ függvénnyel érdemes a második koordinátából az elsőt tippelni, ha az a célunk, hogy a tippelésnél elkövetett hiba négyzetének átlagos értéke a sok kísérlet esetén minél kisebb legyen,
- (a) ha feltesszük, hogy $k(y)$ lineáris,
- (b) ha $k(y)$ tetszőleges valós lehet?
2. X és Y együttes sűrűségfüggvénye $h(x, y) = 60xy^2$, ha $0 \leq x \leq 1$, $0 \leq y \leq 1 - x$. Határozzuk meg a kovarianciájukat. Tegyük fel, hogy a második koordinátát tudjuk megfigyelni és az elsőt ezen megfigyelt adattól függően becsüljük az $x = \frac{2}{3}(1 - y)$ képlet alapján. Van-e ennél jobb módszer, ha a négyzetes eltérés hibáját akarjuk minimalizálni?
3. Statisztikai adatok alapján annak a valószínűsége, hogy ikerszületéskor mindkét gyerek fiú, 0.32, annak a valószínűsége, hogy mindkét gyermek lány, 0.28. Annak a valószínűsége, hogy az első iker fiú és a második lány ugyanannyi, mint fordítva. Jelölje X illetve Y az első, illetve a második gyerek nemét, legyen a felvett értékük fiú esetén 1, lány esetén 0. Számítsuk ki X és Y korrelációs együtthatóját. Hogyan tippelnénk Y ismeretében X -re lineáris függvénnyel, ha a tippelés átlagos négyzetes hibáját akarjuk minimalizálni?