

Valószínűségszámítás jegyzet

Buzga Viktor

March 21, 2011

Contents

1	Bevezető	3
I	Valószínűségszámítás	4
2	Valószínűségi alapfogalmak	5
3	Kolmogorov-féle valószínűségi mező	7
4	Klasszikus valószínűségi mező	10
4.1	Klasszikus valószínűségi mező	10
4.2	Geometriai valószínűségi mező	10
5	Feltételes valószínűség	11
6	A valószínűségi változó	13
6.1	Diszkrét eloszlás	14
6.2	Folytonos eloszlások	15
7	A valószínűségi változó transzformációja	18
8	Várható érték	20
8.1	Nevezetes eloszlások várható értéke:	20
9	Szórásnégyzet	22
9.1	Nevezetes eloszlások szórása:	23
10	Több valószínűségi változó együttes vizsgálata	24
11	Valószínűségi változók összege	27
11.1	Diszkrét esetben	27
11.2	Folytonos esetben	27
11.3	Összeg várható értéke	27
12	Feltételes eloszlás	30

13	Feltételes várható érték	31
14	Nagy számok törvénye	33
15	Markov-láncok	36
II	Matematikai statisztika	38
16	Maximum likelihood becslés	41
17	Hipotézisvizsgálat	43
17.1	Konfidencia-intervallumok	43
17.2	Hipotézisek, próbák	43
17.2.1	Paraméteres próbák	44

Chapter 1

Bevezető

A jegyzet a 2010. évi őszi félévben, Pintér Márta által tartott Valószínűség-számítás kurzus (VISZA208) előadásai alapján készült. Az órákon elhangzottak alapján íródott, azonban nem helyettesíti az órák látogatását, csupán kiegészítést nyújt azokhoz. A jegyzet hibákat tartalmazhat, ezért kérem használóit, hogy amennyiben hibákat fedeznek fel olvasása közben, értesítsenek a vik.barca@gmail.com e-mail címen, hogy azok javításra kerülhessenek. A jegyzetet olyan diákok számára ajánlom, akik az órák látogatása mellett szeretnének pontos képet kapni az ott elhangzottakról.

Part I

Valószínűségszámítás

Chapter 2

Valószínűségi alapfogalmak

Véletlen kísérletnek nevezzük azokat a jelenségeket, amiknek kimeneteit az általunk figyelembe vett feltételek nem határozzák meg. Egy kísérlet lehetséges kimeneteleit *elemi eseményeknek* nevezzük. ω -val jelöljük őket, és mindig pontosan egy következik be közülük. Az elemi események összességét *eseménytérnek* nevezzük és Ω -val jelöljük. *Eseményeknek* hívjuk az eseménytér részhalmazait. Egy A esemény bekövetkezik, ha olyan elemi esemény realizálódik, ami eleme az A eseménynek. *Lehetetlen eseménynek* nevezzük az olyan eseményt, ami soha nem következik be. (Az ötöslottó megnyerése nem lehetetlen esemény, csupán nagyon kis valószínűséggel bekövetkező, viszont az, hogy egyszerre 1 kockával 3-at és párosat dobjunk az lehetetlen.) *Biztos esemény* ezzel ellentétben, amely az összes elemi eseményt tartalmazza, így minden alkalommal bekövetkezik. (Például az, hogy 0-nál nagyobbat dobunk egy szabályos kockával)

Az eseményeket felfoghatjuk halmazoknak, és érvényesek rájuk a halmazműveletek is.

- Két esemény összegén az $A \cup B$ halmazt értjük, vagyis akkor következik be, ha legalább az egyik végbemegy.
- Két esemény szorzatán az $A \cap B$ halmazt értjük, ez tehát akkor következik be, ha mindkettő végbemegy.
- A esemény ellentett eseményén (\bar{A}), vagy komplementerén az $\Omega \setminus A$ halmazt értjük, ami tehát akkor következik be, ha A nem.
- $A \subseteq B$, kiolvasva A maga után vonja a B eseményt. Ha A bekövetkezik, akkor B is.

A megfigyelhető események halmaza az a halmaz, melyről el tudjuk dönteni, hogy egy végbement elemi esemény benne van-e vagy nem. A teljes eseménytér megfigyelhető, jelben $\Omega \in \mathcal{F}$. Ha $A \in \mathcal{F}$ akkor $\bar{A} \in \mathcal{F}$. Ha véges sok esemény megfigyelhető, akkor az összegük is megfigyelhető. Ezen axiómák segítségével belátható, hogy a lehetetlen esemény is megfigyelhető, továbbá, ha véges sok esemény megfigyelhető, akkor azok szorzata is. Két eseményt *kizáró eseménynek*

nevezünk, ha $AB = \emptyset$. $A_1, A_2, \dots, A_n \in \mathcal{F}$ teljes eseményrendszert alkotnak, ha páronként kizáróak és összegük kiadja a teljes eseményteret.

Chapter 3

Kolmogorov-féle valószínűségi mező

Definíció I.1 Valószínűség: Halmazfüggvény, mely a megfigyelhető események halmazáról képez a $[0,1]$ intervallumra. Minden \mathcal{F} -beli eseményre értelmezve van.

Tulajdonságai: (Kolmogorov féle axiómarendszer:)

1. $P(\Omega) = 1$
2. $A_1, A_2, \dots, A_n \in \mathcal{F}$ (vagy megszámlálhatóan sok megfigyelhető esemény) páronként kizáró események, vagyis $A_i A_j = \emptyset \quad \forall i, j$ -re, ekkor $P(\sum_i A_i) = \sum_i P(A_i)$

Egy kísérletsorozat alkalmával n -szer megismétlünk egy kísérletet azonos körülmények között. A korábbi eredmények nem befolyásolják a következő kimenetelét. Az esemény gyakoriságán azt a k_A számot értjük, amely az A esemény bekövetkezéseinek számával egyenlő. Relatív gyakoriság értéke ennek a számnak a kísérletek számára vonatkoztatott hányadosa, jelben $r_n(A) = \frac{k_A}{n}$. A gyakoriság értéke 0 és n közti szám, így a relatív gyakoriság a $[0,1]$ intervallumban van, és $r_n(\Omega) = 1$, hiszen a teljes eseményrendszer eseményei közül mindig legalább az egyik realizálódik. ($n \rightarrow \infty$) esetén a relatív gyakoriság a valószínűséghez tart.

A valószínűség tulajdonságai:

1. $P(\bar{A}) = 1 - P(A)$, mert A és \bar{A} kizáró események és $1 = P(\Omega) = P(A + \bar{A}) = P(A) + P(\bar{A})$.
2. $P(\emptyset) = 0$, mert $\emptyset = \bar{\Omega}$ és $P(\emptyset) = 1 - P(\Omega) = 1 - 1 = 0$.
3. Ha $A_1, A_2, \dots, A_n \in \mathcal{F}$ teljes eseményrendszert alkotnak (páronként kizáróak és összegük kiadja a teljes eseményteret), akkor $\sum P(A_i) = 1$, mert

$$\sum P(A_i) = P\left(\sum A_i\right) = P(\Omega) = 1$$

4. $A \subseteq B$ esetén $P(A) \leq P(B)$, mert $B = AB + \bar{A}B$ így $P(B) = \underbrace{P(AB)}_A + \underbrace{P(\bar{A}B)}_{\geq 0}$, amiből $P(B) \geq P(A)$.

5. $P(B \setminus A) = P(B) - P(AB)$, mert $B = AB + \bar{A}B$, $P(B) = P(AB) + P(\bar{A}B)$, ahol $P(\bar{A}B) = P(B \setminus A)$

Ha A és B nem kizáró események, akkor a két esemény úniójának a valószínűségét a logikai szita módszerével számíthatjuk ki. Ennek értelmében:

$$P(A + B) = P(A) + P(B) - P(AB)$$

Három esemény esetén pedig:

$$P(A + B + C) = P(A) + P(B) + P(C) - P(AB) - P(AC) - P(BC) + P(ABC)$$

Definíció I.2 *Poincaré-formula:* $A_1, A_2, \dots, A_n \in \mathcal{F}$ esetén legyen

$$S_1^n = \sum_{i=1}^n P(A_i) \quad S_2^n = \sum_{1 < i < j < n} P(A_i A_j) \quad S_n^n = P(A_1 A_2 \dots A_n)$$

Ekkor azt mondhatjuk, hogy

$$P\left(\sum_i A_i\right) = \sum_{l=1}^n (-1)^{l+1} S_l^n$$

A tétel bizonyítása teljes indukcióval történik.

Tétel I.1 *Boole-tétel* Ha A_1, A_2, \dots, A_n nem páronként kizáró események, akkor

$$a, P\left(\sum_{i=1}^n A_i\right) \leq \sum_{i=1}^n P(A_i)$$

$$b, P\left(\prod A_i\right) \geq 1 - \sum P(\bar{A}_i)$$

Bizonyítás:

a, $n = 2$ -re a logikai szita segítségével könnyű belátni. Majd teljes indukció segítségével visszavezethető $n = 2$ esetre.

b, A de-Morgan formulák segítségével az állítás egyszerűen belátható.

Folytonossági tulajdonság:

1. Növekvő halmazok tétele:

Ha $A_1 \subseteq A_2 \subseteq A_3 \dots \subseteq A_n \subseteq \dots$ és $A = \sum A_i$, akkor

$$P(A) = \lim_{n \rightarrow \infty} P(A_n)$$

2. Csökkenő halmazok tétele:

Ha $A_1 \supseteq A_2 \supseteq A_3 \dots \supseteq A_n \supseteq \dots$ és $A = \bigcap A_i$, akkor

$$P(A) = \lim_{n \rightarrow \infty} P(A_n)$$

Ezen tulajdonságokkal rendelkezik, az úgynevezett Kolmogorov féle valószínűségi mező, melyet az (Ω, \mathcal{F}, P) értékekkel jellemzünk.

Chapter 4

Klasszikus valószínűségi mező

4.1 Klasszikus valószínűségi mező

Egy kísérlet, mely véges sok kimenetellel rendelkezik $\Omega = \{\omega_1, \omega_2, \omega_3, \dots, \omega_n\}$ esetén klasszikus valószínűségi mezőben $P(\omega_1) = P(\omega_2) = P(\omega_3) = \dots = P(\omega_n) = p$

$$1 = P(\Omega) = P\left(\sum_{i=1}^n \omega_i\right) = \sum_{i=1}^n P(\omega_i) = nP \quad \text{amiből } P = \frac{1}{n}$$

Ha az A esemény k darab elemi eseményt tartalmaz, akkor az A esemény valószínűsége

$$\frac{k}{n} = k \frac{1}{n} = \sum_{\omega_i \in A} P(\omega_i) = P(A)$$

ami a kedvező esetek és az összes esetek hányadosával egyenlő. Tehát klasszikus valószínűségi mezőben

$$P(A) = \frac{\text{kedvező esetek}}{\text{összes esetek}}$$

4.2 Geometriai valószínűségi mező

Geometriai valószínűségi mező esetében a kísérlet eseménytere egy geometriai alakzat területe, maga a kísérlet pedig az alakzat egy pontjának kiválasztása. Az alakzat mérhető területeit nevezzük eseményeknek, és egy esemény bekövetkezik, ha olyan pont kerül kiválasztásra, ami benne van az esemény által lefedett területben. Jelöljük $\mu(A)$ -vel egy A esemény által lefedett terület nagyságát. Ekkor az A esemény bekövetkezésének valószínűsége:

$$P(A) = \frac{\mu(A)}{\mu(\Omega)}$$

Chapter 5

Feltételes valószínűség

Legyen A és B két tetszőleges esemény ($P(B) > 0$). n -szeres kísérletsorozat esetén vegyük csak azokat az eseteket, amiknél B bekövetkezett, és ezek között nézzük A előfordulásait. Ezt nevezzük az A esemény B -re vonatkoztatott relatív gyakoriságának és $\frac{k_{AB}}{k_B} = r_n(A|B)$ -vel jelöljük, ahol k -k a megfelelő események gyakoriságait jelölik.

$$r_n(A|B) = \frac{k_{AB}}{k_B} = \frac{k_{AB}/n}{k_B/n} = \frac{r_n(AB)}{r_n(B)} \longrightarrow \frac{P(AB)}{P(B)} \quad (n \rightarrow \infty)$$

innen ered a következő definíció.

Definíció I.3 Az A esemény B -re vonatkoztatott feltételes valószínűsége:

$$P(A|B) = \frac{P(AB)}{P(B)}$$

Tétel I.2

1. $0 \leq P(A|B) \leq 1$
2. $P(B|B) = 1$, $P(\emptyset|B) = 0$
3. $A_1, A_2, \dots, A_n, \dots \in \mathcal{F}$, $A_i A_j = \emptyset \quad \forall i, j$ -re, akkor

$$P\left(\sum_{i=1}^n (A_i)|B\right) = \sum_{i=1}^n P(A_i|B)$$

Bizonyítás:

1. $A \cdot B \subseteq B \Rightarrow P(AB) \leq P(B) \Rightarrow \frac{P(AB)}{P(B)} \leq 1$
 $P(AB) \geq 0, P(B) > 0 \Rightarrow P(A|B) \geq 0$
2. $B \cdot B = B \Rightarrow P(B \cdot B) = P(B) \Rightarrow \frac{P(B \cdot B)}{P(B)} = 1, \emptyset \cdot B = \emptyset$
 $\Rightarrow P(\emptyset \cdot B) = 0 \Rightarrow P(\emptyset|B) = 0$

3. A_i -k kizáróak $\Rightarrow A_i B$ -k is kizáróak, így

$$P\left(\sum_{i=1}^{\infty} A_i B\right) = \sum_{i=1}^{\infty} P(A_i B)$$

Ezt leosztva $P(B)$ -vel beláttuk az állítást.

A definícióból következik az úgynevezett *szorzási szabály* :

$P(AB) = P(A|B)P(B)$, ami általánosan is igaz:

$$P\left(\prod_{i=1}^n A_i\right) = P(A_n|A_1 \dots A_{n-1})P(A_{n-1}|A_1 \dots A_{n-2}) \dots P(A_2|A_1)P(A_1)$$

Bizonyítása a két változóra vett szorzás szabály alkalmazásával egyszerű.

Tétel I.3 *Teljes valószínűség tétele*

A_1, A_2, \dots, A_n megszámlálhatóan sok esemény teljes eseményrendszert alkot és $P(A_i) > 0 \quad \forall i$ -re. Tetszőleges B esemény valószínűsége:

$$P(B) = \sum_{i=1}^{\infty} P(B|A_i)P(A_i)$$

Tétel I.4 *Bayes tétele*

$A_1, A_2, \dots, A_n, \dots$ megszámlálhatóan sok esemény teljes eseményrendszert alkot és $P(A_i) > 0 \quad \forall i$ -re. Tetszőleges B eseményre:

$$P(A_i|B) = \frac{P(A_i B)}{P(B)} = \frac{P(B|A_i)P(A_i)}{\sum_j P(B|A_j)P(A_j)}$$

Definíció I.4 A és B függetlenek, ha $P(A|B) = P(A)$, vagy $P(B|A) = P(B)$ vagy $P(AB) = P(A)P(B)$.

$$\left(P(AB) = \underbrace{P(A|B)}_{P(A)} P(B) = P(A)P(B) \right)$$

Tétel I.5 A és B függetlenek, akkor \bar{A} és \bar{B} , \bar{A} és B , \bar{B} és A is függetlenek.

Bizonyítás: Elég A és \bar{B} -re belátni: $P(A) = P(AB) + P(A\bar{B}) \Rightarrow$
 $P(A\bar{B}) = P(A) - P(AB) = P(A) - P(A)P(B) = P(A)(1 - P(B)) = P(A)P(\bar{B})$

Tétel I.6 \emptyset és Ω minden más eseménytől függetlenek.

Bizonyítás: $P(A \cdot \Omega) = P(A) = 1 \cdot P(A) = P(\Omega)P(A)$

Bizonyítás: $P(A \cdot \emptyset) = P(\emptyset) = 0 \cdot P(A) = P(\emptyset)P(A)$

Definíció I.5 A_1, A_2, \dots, A_n események páronként függetlenek, ha $P(A_i A_j) = P(A_i)P(A_j) \quad \forall i, j$ -re ($i \neq j$).

Definíció I.6 A_1, A_2, \dots, A_n események teljesen függetlenek, ha bármely k elemet kiválasztva ($2 \leq k \leq n$) $\forall 1 \leq j_1 < j_2 < \dots < j_k \leq n$ -re $P(A_{j_1} \cdot A_{j_2} \cdot \dots \cdot A_{j_k}) = P(A_{j_1})P(A_{j_2}) \dots P(A_{j_k})$

A teljes függetlenségből következik a páronkénti is, de fordítva általában nem igaz.

Chapter 6

A valószínűségi változó

Definíció I.7 Az $X (\Omega \rightarrow R)$ elemi eseményeken értelmezett függvényt *valószínűségi változónak* nevezzük, ha $A = \{\omega, X(\omega) \in \mathcal{B}^1\}$ megfigyelhető esemény.

A valószínűség változó eloszlásán (Q_x) azt a $[0,1]$ értékkészletű halmazfüggvényt értjük, amely megegyezik a valószínűségi változó egy halmazba esésének valószínűségével. Az eloszlás egyértelműen meghatároz egy eloszlásfüggvényt, és fordítva.

Definíció I.8 *Eloszlásfüggvényen* az $F_X(x) = Q_x((-\infty, x)) = P(\{X(\omega) \in (-\infty, x)\}) = P(X < x)$ függvényt értjük, ami $R \rightarrow [0, 1]$ -re képez.

F_x tulajdonságai:

1. Monoton nő. $x > y$ esetén $F_X(x) \geq F_X(y)$, mert $(-\infty, x) \supset (-\infty, y) \Rightarrow$
 $\underbrace{\{\omega, X(\omega) \leq y\}}_a \Rightarrow \underbrace{\{X(\omega) \leq x\}}_b \Rightarrow \underbrace{P(a)}_{F_X(y)} \leq \underbrace{P(b)}_{F_X(x)}$

2. Balról folytonos.

$$\lim_{y \rightarrow x-0} F_X(y) = F_X(x)$$

3.

$$\lim_{x \rightarrow -\infty} F_X(x) = 0, \lim_{x \rightarrow \infty} F_X(x) = 1$$

$P(a \leq x < b)$ valószínűség értéke: $X \in [a, b) \quad (-\infty, b) = (-\infty, a) \cup [a, b)$

$$P(X \in (-\infty, b)) = P(X \in (-\infty, a)) + P(X \in [a, b)) \Rightarrow$$

$$P(a \leq x < b) = P(X < b) - P(X < a) = F_X(b) - F_X(a)$$

¹Borel-halmaz

$$\begin{aligned}
P(a \leq x \leq b) &= F_X(b+0) - F_X(a) \\
P(a < x < b) &= F_X(b) - F_X(a+0) \\
P(a < x \leq b) &= F_X(b+0) - F_X(a+0)
\end{aligned}$$

6.1 Diszkrét eloszlás

Definíció I.9 X , illetve eloszlása *diszkrét*, ha X megszámlálhatóan sok értéket vehet csak fel.

$$X(\omega) \in \{x_1, x_2, \dots\} \quad \forall \omega \in \Omega$$

Ilyenkor $P_i = P(X = x_i) = P(\{\omega : X(\omega) = x_i\})$ valószínűségekkel írjuk le az eloszlást.

$$P(X \in E) = \sum_{x_i \in E} P_i$$

$$F_X(x) = P(X \in (-\infty, x)) = \sum_{x_i < x} P_i$$

Az eloszlásfüggvény lépcsős függvény, mely az x_i pontokban ugrik, és nagysága éppen P_i . $0 \leq P_i \leq 1$, hiszen valószínűség, és $\sum_i P_i = 1$.

Nevezetes diszkrét eloszlások:

1. Indikátoreloszlás: $A \in \mathcal{F}$ $p = P(A) > 0$ esemény, amire

$$X(\omega) = \begin{cases} 1, & \text{ha } A \text{ bekövetkezik, } \omega \in A \\ 0, & \text{ha } A \text{ nem következik be, } \omega \notin A \end{cases}$$

$$p_0 = P(X = 0) = P(\{\omega : \omega \in \Omega \setminus A\}) = P(\bar{A}) = 1 - p$$

$$p_1 = P(X = 1) = P(\{\omega : \omega \in A\}) = P(A) = p$$

Jele: I_A

2. Binomiális eloszlás: n -szeres kísérletsorozat, $A \in \mathcal{F}$ $p = P(A) > 0$ esemény, ahol

$$X = A \text{ bekövetkezéseinek száma, } X \in \{0, 1, \dots, n\}$$

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

Könnyen belátható a binomiális tétel segítségével, hogy valóban eloszlásról van szó, hiszen az összes $0 \leq k \leq n$ egészre összegezve 1-et kapunk.

Jele: $B(n,p)$: n -edrendű, p paraméterű binomiális eloszlás.

($B(1,p) = I_A$) Eloszlás móduszának nevezzük azt a k . tagot, amire p_k a legnagyobb érték amit az eloszlás felvehet. Binomiális eloszlás esetén a módusz $[(n+1)p]$ (Ha egész, akkor a módusz egyenlő $k = (n+1)p-1$ értékével így két módusz van).

3. Poisson eloszlás: $Po(\lambda)$ λ paraméterű eloszlás, ahol $X \in \{0, 1, \dots\}$.

$$p_k = P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad \lambda > 0$$

e^λ Taylor sorának segítségével egyszerűen belátható, hogy eloszlásról van szó. Módusza a $[\lambda]$. tag (egész érték esetén $\lambda-1$. tag is.)

4. Geometriai eloszlás: $G(p)$ p paraméterű eloszlás, ahol $X \in \{0, 1, \dots\}$. Adott $p = P(A) > 0$ valószínűségű A esemény első bekövetkezéséig végrehajtott kísérletek száma X .

$$p_k = P(X = k) = (1 - p)^{k-1} p$$

A geometriai sor konvergenciáját kihasználva megmutatható, hogy eloszlás. Módusza p_1

Tétel I.7 Ha $(n \rightarrow \infty), (p \rightarrow 0)$, úgy, hogy $np = \text{állandó}$. Ekkor $B(n, p) \rightarrow Po(np)$, vagyis $\forall k$ -ra a binomiális eloszlás k -adik tagja tart a Poisson eloszlás k -adik tagjához.

Bizonyítás:

$$\begin{aligned} p_k &= \binom{n}{k} p^k (1-p)^{n-k} = \frac{n(n-1)\dots(n-k+1)}{k! n^k} n^k p^k \frac{(1-p\frac{n}{n})^n}{(1-p)^k} = \\ &= \underbrace{\frac{n(n-1)\dots(n-k+1)}{n^k}}_1 \frac{(np)^k}{k!} \underbrace{\left(1 - \frac{np}{n}\right)^n}_{e^{-np}} \underbrace{\frac{1}{(1-p)^k}}_1 \rightarrow \frac{(np)^k}{k!} e^{-np} = Po(np)_k \end{aligned}$$

Tétel I.8 Geometriai eloszlás örökifjú tulajdonsága:

$\forall k, m \quad P(X = m+k | X > m) = P(X = k)$

Bizonyítás:

$$\begin{aligned} P(X = m+k | X > m) &= \frac{P(X = m+k, X > m)}{P(X > m)} = \frac{P(X = m+k)}{P(X > m)} = \\ &= \frac{(1-p)^{m+k-1} p}{\sum_{l=m+1}^{\infty} (1-p)^{l-1} p} = \frac{(1-p)^{m+k-1} p}{(1-p)^m \underbrace{\sum_{l=1}^{\infty} (1-p)^{l-1} p}_1} = (1-p)^{k-1} p = P(X = k) \end{aligned}$$

6.2 Folytonos eloszlások

Definíció I.10 X valószínűségi változó, illetve eloszlása *folytonos*, ha $\exists f_X(x) \geq 0$ sűrűségfüggvény $\forall a, b \in R$

$$P(X \in (a, b)) = \int_a^b f_X(x) dx$$

Ha $a = -\infty$, $b = x$, akkor $F_X(x) = \int_{-\infty}^x f_X(t) dt$.
 Sűrűségfüggvény $(-\infty, \infty)$ intervallumon vett integrálja 1.
 Folytonos esetben $\forall P(X = a) = 0$, így

$$P(a \leq x \leq b) = P(a < x < b) = P(a < x \leq b) = P(a \leq x < b)$$

Az eloszlásfüggvény deriváltja a sűrűségfüggvény: $f_X(x) = \frac{dF_X(x)}{dx}$
Nevezetes folytonos eloszlások:

1. Egyenletes eloszlás: $U(a,b)$ -val jelölt eloszlás $[a,b]$ -n egyenletes.

$$f_X(x) = \begin{cases} \frac{1}{b-a} & \text{ha } x \in [a, b] \\ 0 & \text{különben} \end{cases}$$

$$F_X(x) = \begin{cases} 0 & \text{ha } x < a \\ \frac{x-a}{b-a} & \text{ha } x \in [a, b] \\ 1 & \text{ha } x > b \end{cases}$$

Egy Δ hosszú intervallum valószínűsége csak az intervallum hosszától függ:

$$P(X \in (c, c + \Delta)) = F_X(c + \Delta) - F_X(c) = \frac{(c + \Delta) - a}{b - a} - \frac{c - a}{b - a} = \frac{\Delta}{b - a}$$

2. Exponenciális eloszlás: $E(\lambda)$, λ paraméterű eloszlás, $\lambda > 0$.

$$f_X(x) = \begin{cases} \lambda e^{-\lambda x} & \text{ha } x > 0 \\ 0 & \text{különben} \end{cases}$$

$$F_X(x) = \begin{cases} 1 - e^{-\lambda x} & \text{ha } x > 0 \\ 0 & \text{különben} \end{cases}$$

A folytonos eloszlások közül az exponenciális az egyetlen örökifjú. Ebből csak azt látjuk be, hogy az exponenciális örökifjú tulajdonsággal rendelkezik:

$$\begin{aligned} P(X < s + t | X \geq s) &= P(X < t) \\ \frac{P(X < s + t | X \geq s)}{P(X \geq s)} &= \frac{P(s \leq X < s + t)}{P(X \geq s)} = \frac{F(s + t) - F(s)}{1 - P(X < s)} = \\ &= \frac{1 - e^{-\lambda(s+t)} - (1 - e^{-\lambda s})}{1 - (1 - e^{-\lambda s})} = \frac{e^{-\lambda s} - e^{-\lambda(s+t)}}{e^{-\lambda s}} = 1 - e^{-\lambda t} = \\ &= F(t) = P(X < t) \end{aligned}$$

3. Normális eloszlás: $N(\mu, \sigma)$ μ és σ paraméterű, ahol $\mu, \sigma \in R$ és $\sigma > 0$

$$\varphi_{\mu, \sigma}(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Ez az úgynevezett haranggörbe. Az eloszlásfüggvény:

$$\Phi_{\mu,\sigma}(x) = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^x e^{-\frac{(u-\mu)^2}{2\sigma^2}} du$$

Standard normális eloszlás: $N(0,1)$, $\mu = 0$, $\sigma = 1$

$$\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$$

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{u^2}{2}} du$$

φ tulajdonságai:

(a) Páros függvény: $\varphi(-t) = \varphi(t)$

(b)

$$\lim_{t \rightarrow -\infty} \varphi(t) = \lim_{t \rightarrow \infty} \varphi(t) = 0$$

(c) $t = 0$ - ban van a maximuma, ami $\frac{1}{\sqrt{2\pi}}$

(d)

$$\int_{-\infty}^{\infty} \varphi(t) dt = 1$$

Φ tulajdonságai:

(a) $\Phi(-x) = 1 - \Phi(x)$, mert

$$\begin{aligned} \Phi(-x) &= \int_{-\infty}^{-x} \varphi(t) dt = 1 - \int_{-x}^{\infty} \varphi(t) dt = 1 - \int_{-\infty}^x \varphi(-t) dt = \\ &= 1 - \int_{-\infty}^x \varphi(t) dt = 1 - \Phi(x) \end{aligned}$$

(b)

$$\lim_{x \rightarrow -\infty} \Phi(x) = 0, \lim_{x \rightarrow \infty} \Phi(x) = 1, \text{ mert eloszlásfüggvény.}$$

(c) Szigorúan monoton nő, mert deriváltja $\varphi(x)$, ami sehol sem negatív.

Chapter 7

A valószínűségi változó transzformációja

Definíció I.11 *A valószínűségi változó transzformációján* egy t függvényt értünk, amely egy X valószínűségi változó értékészletéről, egy Y valószínűségi változó értékészletére képez. Ha X diszkrét, akkor Y is csak diszkrét lehet, fordítva előfordulhat, hogy folytonos valószínűségi változót diszkrétre transzformálunk, ezt hívjuk diszkrétizálásnak, továbbiakban példát is fogunk látni rá.

Példa diszkrét transzformációra:

Ha $X \sim B(n, p)$ és $t(x) = n - x$ akkor

$$\begin{aligned} P(Y = k) &= P(n - X = k) = P(X = n - k) = \\ &= \binom{n}{n-k} p^{n-k} (1-p)^{n-(n-k)} = \\ &= \binom{n}{k} p^{n-k} (1-p)^k \Rightarrow Y \sim B(n, 1-p) \end{aligned}$$

Példa folytonos transzformációra:

X standard normális eloszlás, és $t(x) = X^2$.

$$\begin{aligned} F_Y(y) &= P(Y < y) = P(X^2 < y) = P(-\sqrt{y} < X < \sqrt{y}) = \\ &= \Phi(\sqrt{y}) - \Phi(-\sqrt{y}) = 2(\Phi(\sqrt{y})) - 1 \\ f_Y(y) &= F'_Y(y) = \frac{1}{\sqrt{y}} \frac{1}{\sqrt{2\pi}} e^{-\frac{y}{2}} \quad y \geq 0 \end{aligned}$$

Általánosságban véve a dolgot, azt mondhatjuk, hogy:

- Ha t szigorúan monoton nő:

$$F_Y(y) = P(Y < y) = P(X < t^{-1}(y)) = F_X(t^{-1}(y))$$

- Ha t szigorúan monoton csökken:

$$F_Y(y) = P(Y < y) = P(X > t^{-1}(y)) = 1 - P(X < t^{-1}(y)) = 1 - F_X(t^{-1}(y))$$

A sűrűségfüggvény pedig $f_Y(y) = f_X(t^{-1}(y)) \left| \frac{dt^{-1}(y)}{dy} \right|$, ahol az érték pozitív, ha t szigorúan monoton növekvő, és negatív, ha szigorúan monoton csökkenő függvény.

Tétel I.9 U egyenletes a $[0,1]$ intervallumon és $F(y)$ tetszőleges szigorúan monoton növekvő eloszlásfüggvény, akkor az $Y = F^{-1}(U)$ valószínűségi változó eloszlásfüggvénye $F(y)$ lesz.

Tétel I.10 X szigorúan monoton növekvő $F(x)$ eloszlásfüggvényű valószínűségi változó, akkor az $U = F(X)$ egyenletes eloszlású lesz a $[0,1]$ intervallumon.

Definíció I.12 *Lineáris transzformációnak* hívjuk az $Y = aX + b$ valószínűségi változó transzformációt. ($a, b \in \mathbb{R}$)

Standard normális valószínűségi változón elvégzett $Y = \sigma X + \mu$ transzformáció μ és σ paraméterű normális eloszlást hoz létre:

$$\begin{aligned} F_Y(y) &= F_X\left(\frac{y-\mu}{\sigma}\right) = \Phi\left(\frac{y-\mu}{\sigma}\right) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\frac{y-\mu}{\sigma}} e^{-\frac{t^2}{2}} dt = \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^y e^{-\frac{(u-\mu)^2}{2\sigma^2}} \frac{1}{\sigma} du = \Phi_{\mu,\sigma}(y) \Rightarrow Y \sim N(\mu, \sigma) \end{aligned}$$

A levezetés során felhasználtuk a $t = \frac{u-\mu}{\sigma}$ és a $dt = \frac{1}{\sigma} du$ helyettesítéseket.

Diszkrétizálás során folytonos valószínűségi változóból diszkrétet készítünk egy transzformáció során. Ilyen transzformáció például a $t(x) = [X] + 1$ függvény az $X \sim E(\lambda)$ esetben, melynél:

$$\begin{aligned} P(\lambda = k) &= \int_{k-1}^k \lambda e^{-\lambda x} dx = [-e^{-\lambda x}]_{k-1}^k = e^{-\lambda(k-1)} - e^{-\lambda k} = \\ &= (1 - (1 - e^{-\lambda}))^{k-1} (1 - e^{-\lambda}) \end{aligned}$$

$G(1 - e^{-\lambda})$ geometriai eloszlás jön létre.

Chapter 8

Várható érték

- **Definíció I.13** Ha a $\sum |x_i|P(X = x_i)$ sor konvergens akkor \exists várható érték és értéke:

$$EX = \sum_i x_i P(X = x_i)$$

- **Definíció I.14** Ha a $\int |x|f_X(x)dx < \infty$ akkor \exists várható érték és értéke:

$$EX = \int_{-\infty}^{\infty} x f_X(x) dx$$

$Y = t(x)$ esetén :

$$EY = \sum_i t(x_i)P(X = x_i) \quad \text{diszkrét és} \quad EY = \int_{-\infty}^{\infty} t(x)f_X(x)dx$$

folytonos esetben. Ennek speciális esete a lineáris transzformáció ($Y = aX + b$), amire: (csak folytonosra bizonyítva, diszkrétre a módszer azonos)

$$\begin{aligned} EY = E(aX + b) &= \int_{-\infty}^{\infty} (ax + b)f_X(x)dx = \int_{-\infty}^{\infty} ax f_X(x)dx + \int_{-\infty}^{\infty} b f_X(x)dx = \\ &= a \int_{-\infty}^{\infty} x f_X(x)dx + b \int_{-\infty}^{\infty} f_X(x)dx = a EX + b \end{aligned}$$

8.1 Nevezetes eloszlások várható értéke:

$$EX = \left\{ \begin{array}{l} p \quad ,\text{ha } X \in I_A(p) \\ np \quad ,\text{ha } X \in B(n, p) \\ \lambda \quad ,\text{ha } X \in Po(\lambda) \\ \frac{1}{p} \quad ,\text{ha } X \in G(p) \end{array} \right\} \text{ diszkrét esetben.}$$

$$EX = \left\{ \begin{array}{ll} \frac{b+a}{2} & , \text{ha } X \in U(a, b) \\ \frac{1}{\lambda} & , \text{ha } X \in E(\lambda) \\ \mu & , \text{ha } X \in N(\mu, \sigma) \end{array} \right\} \text{ folytonos esetben.}$$

Mindkét esetben könnyen levezethetjük a megfelelő értékeket, ha felhasználjuk a várható érték definícióját diszkrét vagy folytonos esetben, illetve a megfelelő változók eloszlásait vagy sűrűségfüggvényeit.

A várható értéket nevezik másnéven *első momentumnak* is. Létezik természetesen n-edik momentum is, amit a következőképp definiálhatunk:

$$\mu_n(x) = E(X^n) \begin{cases} \nearrow \sum_{x \in \mathcal{X}} x^n P(X = x) & \text{diszkrét esetben.} \\ \searrow \int_{-\infty}^{\infty} x^n f_X(x) dx & \text{folytonos esetben.} \end{cases}$$

Van konstansra vonatkozó n-edik momentum: $E[(X - c)^n]$ a c-re vonatkozó n-edik momentum. $c = EX$ esetén beszélünk centrális momentumról: $E[(X - EX)^n]$. Második centrális momentum speciális tulajdonságokkal bír, ezt nevezzük szórásnégyzetnek.

Chapter 9

Szórásnégyzet

Definíció I.15 Szórásnégyzetnek nevezzük a $\sigma^2(x) = E[X - EX]^2$ értéket.

Ha valaminek nincs várható értéke, akkor ebből adódóan szórásnégyzete sincs. A szórásnégyzetet felírhatjuk úgy mint az $(X - EX)^2$ várható értékét, felhasználva valószínűségi változó transzformációjának várható értékére vonatkozó állításunkat, a várható érték definíciójában x helyére $(x - EX)^2$ kerül. A szórás a szórásnégyzet pozitív négyzetgyöke.

Szórásnégyzet tulajdonságai:

1. $\sigma^2(X) = E[(X - a)^2] - (E(X - a))^2 = EX^2 - (EX)^2 \quad \forall a$ -ra (Steinertétel)
2. $E(X - a)^2 \geq \sigma^2(x) = E(X - EX)^2 \quad \forall a \in R$
3. $\sigma^2(\alpha X + \beta) = \alpha^2 \sigma^2(X) \quad \forall \alpha, \beta \in R$
4. $\sigma^2 = 0 \Leftrightarrow \exists c \in R \quad P(X = c) = 1$ és $c = EX$.

Bizonyítás:

1.

$$E(X - a)^2 = E(X^2 - 2aX + a^2) = E(X^2) - 2aEX + a^2$$

$$E(X - a) = EX - a \Rightarrow (E(X - a))^2 = (EX - a)^2 = (EX)^2 - 2aEX + a^2$$

A kettő különbsége éppen $E(X^2) - (EX)^2$. Ha a helyére EX -et írunk visszkapjuk $\sigma^2(X)$ értékét.

$$2. \quad E(X - a)^2 = \sigma^2(X) + \underbrace{(E(X - a))^2}_{\geq 0} \geq \sigma^2(X)$$

3.

$$\sigma^2(\alpha X + \beta) = E(\alpha X + \beta)^2 - (E(\alpha X + \beta))^2 =$$

$$\alpha^2 EX^2 + 2\alpha\beta EX + \beta^2 - \alpha^2 (EX)^2 - 2\alpha\beta EX - \beta^2 = \alpha^2 (EX^2 - (EX)^2) = \alpha^2 \sigma^2 X$$

$$\begin{aligned}
4. & \Leftrightarrow (c - c)^2 + 0 = \sigma^2(X) = 0 \\
& \Rightarrow \sigma^2(X) = 0 \Rightarrow E(X - EX)^2 = 0 \Rightarrow \\
& \Rightarrow P((X - EX)^2 = 0) = 1 \Rightarrow P(X - EX) = 1
\end{aligned}$$

Definíció I.16 *Standardizált változónak* nevezzük az: $\tilde{X} = \frac{X - EX}{\sigma X}$ értéket. $E\tilde{X} = 0, \sigma\tilde{X} = 1$.

Tétel I.11 *Markov egyenlőtlenség* Legyen X valószínűségi változó, $X \geq 0$ és $\exists EX (\geq 0)$, tetszőleges $\lambda > 0$ ($\lambda \in R$) számra $P(X > \lambda) \leq \frac{EX}{\lambda}$
Bizonyítás:

$$\begin{aligned}
EX &= \int_0^\infty x f_X(x) dx \geq \int_\lambda^\infty x f_X(x) dx \geq \int_\lambda^\infty \lambda f_X(x) dx = \\
&= \lambda(1 - F_X(\lambda)) = \lambda P(X > \lambda)
\end{aligned}$$

Diszkrét esetre a bizonyítás teljesen analóg a folytonossal, előbb az összegzést kell szűkíteni, majd az x-et kicserélni a nála kisebb λ -ra.

Tétel I.12 *Csebisev egyenlőtlenség* Legyen X valószínűségi változó, $X \geq 0$ és $\exists \sigma X$, tetszőleges $\lambda > 0$ ($\lambda \in R$) számra $P(|X - EX| > \lambda) \leq \frac{\sigma^2 X}{\lambda^2}$
Bizonyítás:

$Y = (X - EX)^2 \geq 0 \Rightarrow \exists EY = E(X - EX)^2 = \sigma^2 X \Rightarrow$ Markov egyenlőtlenség fennáll Y -ra

$$\begin{aligned}
\text{Legyen } \lambda^2 > 0. P(Y \geq \lambda^2) &\leq \frac{EY}{\lambda^2} \Leftrightarrow P((X - EX)^2 \geq \lambda^2) \leq \frac{\sigma^2 X}{\lambda^2} \Leftrightarrow \\
&\Leftrightarrow P(|X - EX| > \lambda) \leq \frac{\sigma^2 X}{\lambda^2}
\end{aligned}$$

9.1 Nevezetes eloszlások szórása:

$$\sigma X = \left\{ \begin{array}{ll} \sqrt{p(1-p)} & , \text{ha } X \in I_A(p) \\ \sqrt{np(1-p)} & , \text{ha } X \in B(n, p) \\ \sqrt{\lambda} & , \text{ha } X \in Po(\lambda) \\ \frac{\sqrt{1-p}}{p} & , \text{ha } X \in G(p) \end{array} \right\} \text{ diszkrét esetben.}$$

$$\sigma X = \left\{ \begin{array}{ll} \frac{b-a}{\sqrt{12}} & , \text{ha } X \in U(a, b) \\ \frac{1}{\lambda} & , \text{ha } X \in E(\lambda) \\ \sigma & , \text{ha } X \in N(\mu, \sigma) \end{array} \right\} \text{ folytonos esetben.}$$

Az értékek ebben az esetben is egyszerűen levezethetők Steiner tételének használatával.

Chapter 10

Több valószínűségi változó együttes vizsgálata

Definíció I.17 $X = \{x_1, x_2, \dots\}$ és $Y = \{y_1, y_2, \dots\}$ valószínűségi változók, ekkor a $P(X = x_i, Y = y_j)$ valószínűségek összességét X és Y együttes eloszlásának nevezzük.

Definíció I.18 $X = \{x_1, x_2, \dots\}$ és $Y = \{y_1, y_2, \dots\}$ valószínűségi változók, ekkor a

$$P(X = x_i) = \sum_j P(X = x_i, Y = y_j)$$

valószínűségek összességét X vetületi, vagy peremeloszlásának nevezzük.

Több valószínűségi változó esetén is létezik peremeloszlás egy és több elemnek is. A módszer ugyanaz, azon valószínűségi változók szerint szummázunk, amelyekre nem vagyunk kíváncsiak.

Definíció I.19 X_1, X_2, \dots, X_d valószínűségi változók esetén az

$$F_{X_1, X_2, \dots, X_d}(x_1, x_2, \dots, x_d) = P(X_1 < x_1, X_2 < x_2, \dots, X_d < x_d)$$

valószínűséget az X_1, X_2, \dots, X_d *együttes eloszlásfüggvényének* nevezzük.

X_1, X_2, \dots, X_d helyettesíthető egy darab vektor értékű valószínűségi változóval.

$\underline{X} = (X_1, X_2, \dots, X_d)$

F_{X_1, X_2, \dots, X_d} tulajdonságai:

1. Minden változójával monoton nő.

$$F_{\underline{X}}(x_1, \dots, x_i, \dots, x_d) \leq F_{\underline{X}}(x_1, \dots, x'_i, \dots, x_d) \quad , \text{ ha } x_i < x'_i$$

$$\forall i \in \{1, \dots, d\}$$

2. Minden változójával balról folytonos.
3. Ha tetszőleges változójával a $-\infty$ -be tartunk, akkor 0-hoz tart, Ha \forall változójával a ∞ -be tartunk, akkor 1-hez tart

Két változó esetén a T téglalapba esés valószínűsége az együttes eloszlásfüggvényekkel írható fel:

$$\begin{aligned} P((X, Y) \in T) &= P(a \leq X \leq b, c \leq Y \leq d) = \\ &= F_{X,Y}(a, c) + F_{X,Y}(b, d) - F_{X,Y}(a, d) - F_{X,Y}(b, c) \end{aligned}$$

Létezik, mint eloszlás esetében, *vetületi, vagy perem-eloszlásfüggvény* is:

Definíció I.20 X_1, X_2, \dots, X_d valószínűségi változók. Tetszőleges k -ra ($1 \leq k \leq d$) a j_1, \dots, j_k indexkombinációra, az $X_{j_1}, X_{j_2}, \dots, X_{j_k}$ együttes eloszlása k dimenziós vetületi eloszlásfüggvény.

Tétel I.13 Az együttes eloszlásfüggvény meghatározza az összes vetületi eloszlásfüggvényt, de fordítva nem igaz, az összes vetületi eloszlásfüggvény sem határozza meg az együttest.

Például $d = 2$ -re:

$$F_X(x) = P(X < x) = P(X < x, Y < \infty) = \lim_{y \rightarrow \infty} F_{X,Y}(x, y)$$

Több változó esetén is hasonló a helyzet. Azokkal, amelyek nem szerepelnek a vetületi eloszlásfüggvényben, a végtelenbe tartunk.

Folytonos esetben az eloszlásfüggvényen kívül létezik sűrűségfüggvény is.

Definíció I.21 (X, Y) , illetve eloszlásuk folytonos, ha $\exists f_{X,Y}(x, y) \geq 0$ a sík minden E részhalmazára, és

$$P((X, Y) \in E) = \iint_E f_{X,Y}(x, y) dx dy$$

ahol $f_{X,Y}(x, y)$ az együttes sűrűségfüggvény.

Az együttes eloszlásfüggvényt megkapjuk a következőképpen:

$$F_{X,Y}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X,Y}(u, v) dv du$$

Fordítva parciális deriválással juthatunk a sűrűségfüggvény értékéhez:

$$f_{X,Y}(x, y) = \frac{\partial^2 F_{X,Y}(x, y)}{\partial x \partial y}$$

A vetületi sűrűségfüggvényeket megkaphatjuk, hogyha az együttes sűrűségfüggvényt a $(-\infty, \infty)$ intervallumon kiintegáljuk a másik változó szerint, tehát $f_X(x)$ -hez y -szerinti, $f_Y(y)$ -hoz x szerinti integrálással juthatunk. Több dimenzióban is hasonlóan működik az együttes sűrűségfüggvényből a perem sűrűségfüggvények előállítására, vagyis azok szerint integrálunk, amelyek értéke nem lesz benne a vetületi sűrűségfüggvényben. Az együttes sűrűségfüggvény összes változója szerinti $(-\infty, \infty)$ intervallumokon vett d -szeres integrálja 1.

Definíció I.22 X és Y függetlenek, ha $\forall a, b, c, d \in R$
 $P(a \leq X \leq b, c \leq Y \leq d) = P(a \leq X \leq b)P(c \leq Y \leq d)$

Definíció I.23 X és Y függetlenek, ha $F_{X,Y}(x, y) = F_X(x)F_Y(y)$.

A két definíció ekvivalens egymással. X és Y valószínűségi változók esetén, diszkrét esetben függetlenek, ha

$P(X = x_i, Y = y_i) = P(X = x_i)P(Y = y_i)$, folytonos esetben pedig, ha $f_{X,Y}(x, y) = f_X(x)f_Y(y)$. Több valószínűségi változó esetén van páronkénti és teljes függetlenség.

Definíció I.24 X_1, X_2, \dots, X_n páronként függetlenek, ha X_i és X_j független $\forall i, j$ -re.

Definíció I.25 X_1, X_2, \dots, X_n teljesen függetlenek, ha bármely k elemet kiválasztva ($2 \leq k \leq n$) $\forall j_1, j_2, \dots, j_k$ indexkombinációra
 $F_{X_{j_1} \dots X_{j_k}}(x_{j_1} \dots x_{j_k}) = F_{X_{j_1}}(x_{j_1})F_{X_{j_2}}(x_{j_2}) \dots F_{X_{j_k}}(x_{j_k})$

A teljes függetlenségből következik a páronkénti függetlenség, fordítva általában nem igaz.

Chapter 11

Valószínűségi változók összege

11.1 Diszkrét esetben

X és Y diszkrét valószínűségi változók, $X, Y \geq 0$, és egészek. $Z = X + Y$.

$$\begin{aligned} P(Z = k) &= P(X + Y = k) = \sum_{i=0}^k P(X = i, Y = k - i) = \\ &\underbrace{=}_{\text{függetlenek}} \sum_{i=0}^k P(X = i)P(Y = k - i) \end{aligned}$$

Példa erre ha $X \sim Po(\lambda)$ és $Y \sim Po(\mu)$ és függetlenek. Ekkor a $Z = X + Y$ eloszlása $Po(\lambda + \mu)$.

11.2 Folytonos esetben

Ha folytonosak, akkor

$$f_Z(z) = \int_{-\infty}^{\infty} f_{X,Y}(t, z-t) dt \quad \underbrace{=}_{\text{függetlenek}} \int_{-\infty}^{\infty} f_X(t) f_Y(z-t) dt$$

$X, Y \in E(\lambda)$ független valószínűségi változók esetén $f_Z(z) = \lambda^2 z e^{-\lambda z}$
 n változó esetén $f_Z(z) = \frac{\lambda^n z^{n-1}}{(n-1)!} e^{-\lambda z}$

11.3 Összeg várható értéke

Egyszerűen bizonyítható, hogy X_1, X_2, \dots, X_n valószínűségi változók esetén az összeg várható értéke, a várható értékek összege, jelben:

$$E(X_1 + X_2 + \dots + X_n) = EX_1 + EX_2 + \dots + EX_n$$

Tétel I.14 $X_1, X_2, \dots, X_n, Y = g(X_1, X_2, \dots, X_n)$. Y várható értéke:

- Diszkrét esetben: $EY = Eg(X_1, X_2, \dots, X_n) = \sum \sum \dots \sum g(X_1, X_2, \dots, X_n) P(X_1 = x_1, \dots, X_n = x_n)$
- Folytonos esetben: $EY = Eg(X_1, X_2, \dots, X_n) = \int \dots \int g(X_1, X_2, \dots, X_n) f_{X_1, X_2, \dots, X_n}(X_1, X_2, \dots, X_n) dx_1, dx_2, \dots, dx_n$

Tétel I.15 Ha X és Y független valószínűségi változók, akkor $E(XY) = E(X)E(Y)$.

Bizonyítás: (Csak folytonosra bizonyítjuk, diszkrétre a levezetés analóg.)

$$E(XY) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xy f_X(x) f_Y(y) dx dy = \underbrace{\int_{-\infty}^{\infty} x f_X(x) dx}_{EX} \underbrace{\int_{-\infty}^{\infty} y f_Y(y) dy}_{EY}$$

Tétel I.16 X és Y függetlenek és \exists szórásnégyzetük: $\sigma^2(X \pm Y) = \sigma^2 X + \sigma^2 Y$

A bizonyítás Steiner tételének felírásával egyszerűen levezethető, ha felírjuk az összeg szórásnégyzetére.

Definíció I.26 X és Y valószínűségi változók *kovarianciáján* az $E((X - EX)(Y - EY))$ értéket értjük.

$$\begin{aligned} cov(X, Y) &= E((X - EX)(Y - EY)) = E(XY + EXEY - XEY - YEY) = \\ &= E(XY) + EXEY - EXEY - EYEX = E(XY) - EXEY \\ \Rightarrow \sigma^2(X \pm Y) &= \sigma^2 X + \sigma^2 Y \pm 2cov(X, Y), cov(X, X) = \sigma^2 X. \end{aligned}$$

Definíció I.27 *Korrelációs együtthatónak* nevezzük az $R(X, Y) = \frac{cov(X, Y)}{\sigma_X \sigma_Y}$ -t.

Definíció I.28 X és Y korrelálatlanok, ha $cov(X, Y) = 0$ vagy $R(X, Y) = 0$.

Tétel I.17 Ha X és Y független valószínűségi változók, akkor korrelálatlanok, de fordítva általában nem igaz.

Tétel I.18 Ha $a, b \in R$, akkor $cov(aX + bY, Z) = acov(X, Z) + bcov(Y, Z)$

Bizonyítás:

$$\begin{aligned}E((aX + bY) \cdot Z) &= E(aXZ + bYZ) = aE(XZ) + bE(YZ) \\E(aX + bY)EZ &= (aEX + bEY)EZ = aEXEZ + bEY EZ \\cov(aX + bY, Z) &= a \underbrace{(EXZ - EXEZ)}_{cov(X,Z)} + b \underbrace{(EYZ - EY EZ)}_{cov(Y,Z)}\end{aligned}$$

Tétel I.19 $-1 \leq R(X, Y) \leq 1$

$$\Rightarrow |cov(X, Y)| \leq \sigma_X \sigma_Y$$

Tétel I.20

$$\sigma^2(X_1 + X_2 + \dots + X_n) = \sum_{i=1}^n \sigma^2 X_i + 2 \sum_{j>i} cov(X_i, X_j)$$

Több valószínűségi változó, X_1, X_2, \dots, X_n , vagy $\underline{X} = \{X_1, X_2, \dots, X_n\}$ kovarianciamátrixa:

$$\begin{bmatrix} cov(X_1, X_1) & cov(X_1, X_2) & \dots & cov(X_1, X_n) \\ cov(X_2, X_1) & cov(X_2, X_2) & \dots & cov(X_2, X_n) \\ \vdots & \vdots & \ddots & \vdots \\ cov(X_n, X_1) & cov(X_n, X_2) & \dots & cov(X_n, X_n) \end{bmatrix}$$

Chapter 12

Feltételes eloszlás

Definíció I.29 $A \in \mathcal{F}, P(A) > 0$ eseményre $F_X(x|A) = P(X < x|A) = \frac{P(X < x, A)}{P(A)}$ valószínűséget az X A-ra vonatkozó feltételes eloszlásának nevezzük. Ha X és Y diszkrét valószínűségi változók, akkor a $P(X = x_i|Y = y_i)$ valószínűséget az X -nek az Y -ra vonatkoztatott feltételes eloszlásának nevezzük.

Az eloszlásfüggvény definíciójából egyszerűen levezethető, hogy:

$$F_{X|Y}(x|y) = \frac{\frac{\partial F_{X,Y}(x,y)}{\partial y}}{f_Y(y)}$$

Folytonos esetben a feltételes sűrűségfüggvény ennek az eloszlásfüggvénynek a deriváltja:

$$f_{X|Y}(x|y) = \frac{\frac{\partial^2 F_{X,Y}(x,y)}{\partial y \partial x}}{f_Y(y)} = \frac{f_{X,Y}(x,y)}{f_Y(y)}$$

Ez utóbbi miatt $f_{X,Y}(x,y) = f_{X|Y}(x|y)f_Y(y) = f_{Y|X}(y|x)f_X(x)$, és ha X és Y függetlenek, akkor $f_{Y|X}(y|x) = f_Y(y)$, és $f_{X|Y}(x|y) = f_X(x)$. Mindkét esetben érvényes marad teljes valószínűség tétele, mely szerint:

$$F_X(x) = \sum_i F_X(x|A_i)P(A_i)$$

$$f_X(x) = \sum_i f_X(x|A_i)P(A_i)$$

ahol A_i -k teljes eseményrendszert alkotnak.

Chapter 13

Feltételes várható érték

Definíció I.30 Az X valószínűségi változó A eseményre vonatkoztatott feltételes várható értéke diszkrét esetben $\sum x_i P(X = x_i|A)$, folytonos esetben $\int x f_X(x|A) dx$.

Ha A_i -k teljes eseményrendszert alkotnak, akkor a teljes valószínűség tétele itt is alkalmazható:

$$EX = \sum_i E(X|A_i)P(A_i)$$

Definíció I.31 X -nek az Y -ra vonatkozó várható értékén, vagy regresszióján az $E(X|Y) = r(Y)$ értéket értjük, ahol $r(y) = \int x f_{X|Y}(x, y) dx$ folytonos esetben, míg $r(y) = \sum x P(X = x_i|Y = y_i)$ diszkrét esetben.

Regresszió tulajdonságai:

- $E(E(X|Y)) = \int f_Y(y)r(y)dy = \int (\int x f_{X|Y}(x|y)dx) f_Y(y)dy =$
 $= \iint x f_{X|Y}(x|y)f_Y(y)dydx = \int x (\int f_{X,Y}(x, y)dy) dx = \int x f_X(x)dx = EX$
- $E(h(Y)X|Y) = h(Y)E(X|Y)$, mert $\forall y$ -ra $E(h(Y)X|Y = y) =$
 $= \int h(Y)x f_{X|Y}(x|y)dx = h(Y) \int x f_{X|Y}(x|y)dx = h(Y)E(X|Y = y)$
- Ha X és Y függetlenek, akkor $E(X|Y) = EX$, mert $\forall y$ -ra $E(X|Y = y) =$
 $= \int x f_{X|Y}(x|y)dx = \int x f_X(x)dx = EX$

Tétel I.21 Bármely $d(Y)$ függvényre igaz, hogy $E(X - d(Y))^2 \geq E(X - r(Y))^2$, ahol $r(Y)$ a regressziós függvény.

Normális eloszlás esetén a regresszió lineáris. $E(X|Y = y) = aY + b$, ahol $a = \frac{\sigma_1}{\sigma_2} f$, és $b = \mu_1 - \frac{\sigma_1}{\sigma_2} f \mu_2$

Definíció I.32 X és Y valószínűségi változók lineáris regresszióján, azt az $a^*Y + b^*$ valószínűségi változót értjük, amire, $E(X - (a^*Y + b^*))^2$ minimális értékű. Deriválás használatával egyszerűen levezethető, hogy $a^* = R(X, Y) \frac{\sigma_X}{\sigma_Y}$ illetve $b^* = EX - a^*EY$.

Chapter 14

Nagy számok törvénye

Az előző fejezetekből már ismert a relatív gyakoriság értéke, $r_n(A) = \frac{k_A}{n}$, aminek határértéke a $P(A)$ valószínűség, ahol k_A az A bekövetkezéseinek száma n kísérletből.

Definíció I.33 X_n valószínűségi változó sorozat *egy valószínűséggel konvergál* az X -hez, ha

$$P(\{\omega : \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)\}) = 1$$

jelben :

$$X_n \xrightarrow{1p} X$$

Definíció I.34 X_n valószínűségi változó sorozat *sztochasztikusan konvergál* az X -hez, ha

$$\lim_{n \rightarrow \infty} P(\{\omega : |X_n(\omega) - X(\omega)| > \varepsilon\}) = 0$$

jelben :

$$X_n \xrightarrow{st} X$$

Definíció I.35 X_n valószínűségi változó sorozat *eloszlásban konvergál* az X -hez, ha

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_X(x) \quad \forall x \in \mathbb{R} - re,$$

ahol $F_X(x)$ folytonos, jelben :

$$X_n \xrightarrow{e} X$$

Tétel I.22 A Nagy számok törvényének Bernoulli féle gyenge alakja:

Legyenek X_i ($i = 1, 2, \dots, n$) valószínűségi változók függetlenek és azonos indikátor eloszlásúak ($EX_i = p$). Ekkor

$$r_n(A) \xrightarrow{st} P(A)$$

vagyis

$$\lim_{n \rightarrow \infty} P(|r_n(A) - P(A)| > \varepsilon) = 0 \quad \forall \varepsilon > 0$$

Bizonyítás:

$$\begin{aligned} E(r_n(A)) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n EX_i = \frac{1}{n} nP(A) = P(A) \\ \sigma^2(r_n(A)) &= \sigma^2\left(\frac{1}{n} \sum_{i=1}^n x_i\right) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 x_i = \frac{1}{n^2} nP(A)(1 - P(A)) = \\ &= \frac{P(A)(1 - P(A))}{n} \\ P(|r_n(A) - P(A)| > \varepsilon) &= P(|r_n(A) - E(r_n(A))| > \varepsilon) \leq \frac{\sigma^2(r_n(A))}{\varepsilon^2} = \\ &= \frac{P(A)(1 - P(A))}{n\varepsilon^2} \rightarrow 0 \end{aligned}$$

ha $n \rightarrow \infty$

Tétel I.23 A Nagy számok törvényének Csebisev féle gyenge alakja:

Legyenek X_i ($i = 1, 2, \dots$) valószínűségi változók függetlenek, és azonos eloszlásúak. \exists közös várható értékük ($EX_i = \mu$) és közös szórásnégyzetük. Legyen $Z_n = \frac{X_1 + X_2 + \dots + X_n}{n}$, akkor

$$Z_n \xrightarrow{st} \mu$$

vagyis

$$\lim_{n \rightarrow \infty} P(|Z_n - \mu| > \varepsilon) = 0 \quad \forall \varepsilon > 0$$

Bizonyítás:

$$\begin{aligned} E(Z_n) &= E\left(\frac{X_1 + X_2 + \dots + X_n}{n}\right) = \frac{1}{n} \sum_{i=1}^n EX_i = \frac{1}{n} n\mu = \mu \\ \sigma^2(Z_n) &= \sigma^2\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 X_i = \frac{1}{n^2} nd^2 = \frac{d^2}{n} \\ P(|Z_n - EZ_n| \geq \varepsilon) &= P(|Z_n - \mu| \geq \varepsilon) \leq \frac{\sigma^2 Z_n}{\varepsilon^2} = \frac{d^2}{n\varepsilon^2} \rightarrow 0 \end{aligned}$$

ha $n \rightarrow \infty$

Tétel I.24 A Nagy számok törvényének Kolmogorov féle erős alakja:

Legyenek X_i ($i = 1, 2, \dots$) valószínűségi változók teljesen függetlenek. \exists közös

várható értékük ($EX_i = \mu$) és szórásnégyzetükre $\sum_{i=1}^{\infty} \sigma^2 X_i \frac{1}{i^2} < \infty$. $Z_n = \frac{X_1 + X_2 + \dots + X_n}{n}$, amire

$$Z_n \xrightarrow{1\psi} \mu$$

vagyis

$$P\left(\lim_{n \rightarrow \infty} Z_n = \mu\right) = 1$$

Tétel I.25 Centrális határelloszlási tétel:

Legyenek X_i ($i = 1, 2, \dots$) valószínűségi változók páronként függetlenek, és azonos eloszlásúak. \exists közös várható értékük ($EX_i = \mu$) és közös szórásnégyzetük. $Z_n = \frac{X_1 + X_2 + \dots + X_n - n\mu}{\sqrt{n}\sigma}$ -re

$$Z_n \xrightarrow{e} Z$$

, ahol $Z \in N(0, 1)$ vagyis

$$F_{Z_n}(x) = P(Z_n < x) = P\left(\frac{X_1 + X_2 + \dots + X_n - n\mu}{\sqrt{n}\sigma} < x\right) \rightarrow \Phi(x)$$

($n \rightarrow \infty$) $\forall x \in R$

Tétel I.26 Moire-Laplace tétel:

Legyenek X_i ($i = 1, 2, \dots$) valószínűségi változók függetlenek, és azonos indikátor eloszlásúak. \exists közös várható értékük ($EX_i = p$) és közös szórásnégyzetük ($p(1-p)$). Ekkor $Z_n = \frac{X_1 + X_2 + \dots + X_n - np}{\sqrt{np(1-p)}}$ -re

$$Z_n \xrightarrow{e} Z$$

, ahol $Z \in N(0, 1)$ vagyis

$$F_{Z_n}(x) = P(Z_n < x) = P\left(\frac{X_1 + X_2 + \dots + X_n - np}{\sqrt{np(1-p)}} < x\right) \rightarrow \Phi(x)$$

($n \rightarrow \infty$) $\forall x \in R$

Chapter 15

Markov-láncok

Legyen az $X_1, X_2, \dots, X_n, \dots$ valószínűségi változó sorozat. Általában az n -edik valószínűségi változó függ, az előzőektől. Egyszerűbb eset, hogyha csak az öt megelőző néhánytól függ. Ennek speciális esete, ha csupán az öt közvetlenül megelőzőtől függ, ekkor beszélünk Markov-lánccról.

Definíció I.36 $X_1, X_2, \dots, X_n \in S$ -állapottér esetén, ha $\forall n \geq 1$ -re

$$P(X_n = x_n | X_0 = x_0, X_1 = x_1, \dots, X_{n-1} = x_{n-1}) = P(X_n = x_n | X_{n-1} = x_{n-1})$$

akkor a valószínűségi változó sorozat *Markov-lánc*.

Átmenet valószínűségnek nevezzük azt a valószínűséget, mely megmondja, hogy egy állapotból, valamelyik másik állapotba milyen valószínűséggel jutunk. Például a $P(X_n = 2 | X_{n-1} = 3) = 1/2$ annak a valószínűsége, hogy ha az $n-1$ -edik állapot a 3, az n edik állapot, a 2 lesz. Az átmenet valószínűségek általában függenek n -től (időtől). Ha az átmenet valószínűségek függetlenek az n -től, akkor stacionáriusnak nevezzük őket, a Markov-lánccot pedig homogénnek. Homogén Markov-lánccot egyértelműen meghatározza kezdeti eloszlása, vagyis bármelyik állapotának eloszlása.

$$P(X_1 = j | X_0 = i) = P(X_n = j | X_{n-1} = i)$$

$\forall n$ -re, ha a Markov-lánc homogén.

Definíció I.37 Legyen a $X_1, X_2, \dots, X_n, \dots$ valószínűségi változók által alkotott valószínűségi változó sorozat Markov-lánc. Ekkor a Markov-lánc Π , úgynevezett *átmenetvalószínűség mátrixán* egy mátrixot értünk, amire

$$[\Pi]_{ij} = P_{ij} = P(X_1 = j, X_0 = i) \quad (i, j \in S)$$

Definíció I.38 Legyen a $X_1, X_2, \dots, X_n, \dots$ valószínűségi változók által alkotott valószínűségi változó sorozat Markov-lánc. Ekkor a Markov-lánc $[\Pi]^n$, úgynevezett *n lépéses átmenetvalószínűség mátrixán* egy mátrixot értünk, amire

$$[\Pi]_{ij}^{(n)} = P_{ij}^{(n)} = P(X_n = j, X_0 = i) \quad (i, j \in S)$$

A mátrix méretét az állapotok száma adja, ha $|S| = k \Rightarrow k^*k$ -as a mátrix.

Definíció I.39 *Kezdeti eloszlás sorvektorának* nevezzük a $P^{(0)}$ értéket, ha $P_i^{(0)} = P(X_0 = i), \forall(i \in S)$

Definíció I.40 *n-edik abszolút eloszlás sorvektorának* nevezzük a $P^{(n)}$ értéket, ha $P_i^{(n)} = P(X_n = i), \forall(i \in S)$

A kezdeti és n-edik abszolút eloszlás sorvektorai kapcsolatban állnak egymással:
 $P^{(n)} = P^{(0)}\Pi^n$

Tétel I.27 Chapmann-Kolmogorov tétel:

$$\Pi^{(n)} = \Pi^{(i)}\Pi^{(n-i)} = \Pi^n \quad \forall i\text{-re}$$

ahol $\Pi^{(n)}$ a fenti által definiált n-lépéses átmenetvalószínűség mátrix, míg Π^n a fenti definícióval leírt átmenetvalószínűség mátrix n-edik hatványa.

Definíció I.41 A $P^{(\infty)} = \lim P^{(n)}$ értéket *határeloszlásnak* nevezzük, ha létezik. Értéke nem függ P^0 -tól, és eloszlás.

A határeloszlás nem függ a kezdeti eloszlástól, tehát $P^{(\infty)}$ nem függ $P^{(0)}$ -tól. A határeloszlásra továbbá igaz, hogy:

$$P^{(\infty)} = \lim_{n \rightarrow \infty} P^{(n)} = \lim_{n \rightarrow \infty} (P^{(n-1)}\Pi) = \left(\lim_{n \rightarrow \infty} P^{(n-1)} \right) \Pi = P^{(\infty)}\Pi$$

Definíció I.42 A Markov-láncot stabilnak nevezzük abban az esetben, ha létezik határeloszlása.

Part II

Matematikai statisztika

A matematikai statisztika a valószínűségi tér azon elemeivel foglalkozik, ahol a valószínűség nem ismert, esetleg feltételezéseink vannak csupán értékére. Ekkor hívjuk segítségül a statisztikát, melyben a megfigyeléseinkre alapozva állítunk fel becsléseket, melyekkel megpróbáljuk előrevetíteni a kimeneteleket, és megbecsülni a valószínűséget.

Definíció II.1 Az $\mathbf{X} = (X_1, X_2, \dots, X_n)^T$ statisztikai megfigyelést *statisztikai mintának* nevezzük, ha X_i -k teljesen független, azonos eloszlású valószínűségi változók $\forall P \in \mathcal{P}$ esetén, azaz

$$P(X_i < x) = F_p(x) \quad (i = 1, 2, 3, \dots, n)$$

és

$$P(X_{i_1} < x_{i_1}, X_{i_2} < x_{i_2}, \dots, X_{i_k} < x_{i_k}) = \prod_{\alpha=1}^k F_p(x_{i_\alpha}) \quad (\forall 2 \leq k \leq n)$$

A mintának egy $T_n = T_n(X_1, X_2, \dots, X_n)$ függvénye, vagy statisztikai függvény.

Definíció II.2 A $T_n(X_1, X_2, \dots, X_n)$ statisztika sorozat a $\vartheta \in R$ paraméter *torzítatlan becslése*, ha $E(T_n) = \vartheta$

Definíció II.3 A $T_n(X_1, X_2, \dots, X_n)$ statisztika sorozat a $\vartheta \in R$ paraméter *asszimptotikusan torzítatlan becslése*, ha

$$\lim_{n \rightarrow \infty} E(T_n) = \vartheta$$

A következő definíciókhoz felhasználtuk, az előző fejezetben tárgyalt sztochasztikus és egy valószínűségű konvergenciák definícióit.

Definíció II.4 A $T_n(X_1, X_2, \dots, X_n)$ statisztika sorozat a $\vartheta \in R$ paraméter *konzisztens becslése*, ha T_n sztochasztikusan konvergál ϑ -hoz, vagyis ha $\forall P \in \mathcal{P}$ és $\varepsilon > 0$ esetén

$$\lim_{n \rightarrow \infty} P(|T_n - \vartheta| > \varepsilon) = 0$$

ahol \mathcal{P} a lehetséges paraméteres eloszlásaink halmaza.

Definíció II.5 A $T_n(X_1, X_2, \dots, X_n)$ statisztika sorozat a $\vartheta \in R$ paraméter *erősen konzisztens becslése*, ha T_n egy valószínűséggel konvergál ϑ -hoz.

Definíció II.6 A $T_n(X_1, X_2, \dots, X_n)$ statisztika sorozat a $\vartheta \in R$ paraméter *négyzetes középben konzisztens becslése*, ha

$$\lim_{n \rightarrow \infty} E(T_n - \vartheta)^2 = 0$$

Tétel II.1 Ha $T_n(X_1, X_2, \dots, X_n)$ statisztika erősen, vagy négyzetes középben konzisztens, akkor konzisztens.

Tétel II.2 Ha $T_n(X_1, X_2, \dots, X_n)$ statisztika aszimptotikusan torzítatlan és szórása 0-hoz tart ($n \rightarrow \infty$), akkor konzisztens.

Definíció II.7 A $T_1(X_1, X_2, \dots, X_n)$ és $T_2(X_1, X_2, \dots, X_n)$ statisztika a $\vartheta \in R$ paraméter két torzítatlan becslése, akkor T_1 *hatásosabb* a T_2 -nél, ha $\sigma^2(T_1) \leq \sigma^2(T_2) \forall \vartheta \in R$, és $\exists \vartheta_0 \in R$, hogy $\sigma_{\vartheta_0}^2(T_1) < \sigma_{\vartheta_0}^2(T_2)$

Egy T_n statisztikát hatásosnak nevezünk, ha minden T -nél hatásosabbnak bizonyul.

Vannak speciális statisztikák, melyekre erős szabályok érvényesek, tekintsük most meg ezeket:

Definíció II.8 Az $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ statisztikát, az X_1, X_2, \dots, X_n statisztikai minta *átlag*, vagy *empirikus közép statisztikájának* nevezzük.

Definíció II.9 Az $s_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ statisztikát, az X_1, X_2, \dots, X_n statisztikai minta *empirikus szórásnégyzet statisztikájának* nevezzük.

Definíció II.10 Az $s_n^{*2} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ statisztikát, az X_1, X_2, \dots, X_n statisztikai minta *korrigált empirikus szórásnégyzet statisztikájának* nevezzük.

Az empirikus szórásnégyzet statisztika a ϑ szórásnégyzet aszimptotikusan torzítatlan becslése. A korrigált empirikus szórásnégyzet a ϑ szórásnégyzet torzítatlan becslése. A lineáris statisztikák közül az \bar{x}_n a leghatásosabb. Ha két becslés a paraméter hatásos becslései, akkor a két becslés egyezési valószínűsége egy. Ezek azok a tulajdonságok, amelyek hasznossá teszik a becslések használatát.

Chapter 16

Maximum likelihood becslés

A maximum likelihood becslés egy módszert kínál számunkra, melyben egy becsléshez megfelelő statisztikát tudunk választani.

Definíció II.11 Legyen adott az X_1, X_2, \dots, X_n diszkrét eloszlású statisztikai minta. Legyen

$$L(x, \vartheta) = \prod_{i=1}^n P_{\vartheta}(X_i = x_i)$$

a statisztikai minta együttes eloszlása. Ekkor a minta *maximum likelihood becslésén* azt a $T_n(X_1, X_2, \dots, X_n)$ statisztikát értjük, amire $L(x, T_n)$ maximális.

Definíció II.12 Legyen adott az X_1, X_2, \dots, X_n abszolút folytonos eloszlásfüggvényű statisztikai minta. Legyen

$$L(x, \vartheta) = \prod_{i=1}^n f_{\vartheta}(x_i)$$

a statisztikai minta együttes sűrűségfüggvénye. Ekkor a minta *maximum likelihood becslésén* azt a $T_n(X_1, X_2, \dots, X_n)$ statisztikát értjük, amire $L(x, T_n)$ maximális.

Az $L(x, \vartheta)$ függvényt hívják likelihood függvénynek. A maximális érték meghatározásához deriválást használunk, azonban mivel ezen függvények általában bonyolult kinézetűek, eléggé problémás a deriválásuk. Felhasználjuk azt, hogy a természetes alapú logaritmus szigorúan monoton növekvő függvény, így maximumhelyei ugyanott lépnek fel, mint a likelihood függvénynél. Ennek okán sokszor egyszerűbb az úgynevezett log-likelihood függvényre megoldani a maximumkeresés feladatát. A log-likelihood függvény a likelihood függvény természetes alapú logaritmus, vagyis $l(x, \vartheta) = \ln L(x, \vartheta)$, amiből

$$l(x, \vartheta) = \sum_{i=1}^n \ln(f_{\vartheta}(x_i))$$

A megoldásokat a loglikelihood függvény θ_i paraméter szerinti parciális deriváltjainak azok k értékeinél kell vizsgálnunk, ahol a derivált 0. Az átlagstatisztika és az empirikus szórásnégyzet statisztika normál esetben az elméleti várható érték és szórásnégyzet maximum likelihood becslései. Poisson eloszlású statisztikai minta esetén az átlagstatisztika a várható érték maximum likelihood becslése, míg egyenletes eloszlásnál, a maximumstatisztikáról látható be ugyanez. A hatásos becslés, ha létezik ilyen, egy statisztikai minta esetében, a maximum likelihood becslés.

Chapter 17

Hipotézisvizsgálat

17.1 Konfidencia-intervallumok

Az eddigi esetekben az úgynevezett pontbecslésekről volt szó, ahol pontosan próbáltuk meghatározni a paramétert. Folytonos esetben annak a valószínűsége, hogy egy valószínűségi változó éppen egy megadott pontot vegyen fel, nulla (lásd visszább...), így ezekben az intervallumbecslések használata vezet eredményre, ahol a mintákból tartományokat határozunk meg, melyekbe a paraméter nagy valószínűséggel belesik.

Definíció II.13 Legyen $X_1, \dots, X_n \in N(0, 1)$ teljesen független valószínűségi változók, ekkor az $Y = \sum_{i=1}^n X_i^2$ valószínűségi változó eloszlása n -szabadságfokú χ^2 eloszlás.

Definíció II.14 Legyen $X_1, X_2, \dots, X_n \in N(0, 1), Y \in N(0, 1)$ függetlenek, ekkor a $Z = \frac{Y}{\sqrt{\frac{\sum_{i=1}^n X_i^2}{n}}}$ eloszlása n -szabadságfokú t vagy Student eloszlás.

Tétel II.3 Az $X_1, X_2, \dots, X_n \in N(m, D)$ -ből álló statisztikai minta esetén Lukács tétele a következőket mondja:

- $\bar{x}_n \in N(m, \frac{D}{n})$
- $\frac{ns_n^2}{D^2} \in \chi_{n-1}^2$, $n-1$ szabadságfokú χ^2 eloszlású.
- \bar{x}_n és s_n^2 függetlenek, illetve \bar{x}_n és s_n^{*2} is függetlenek.

17.2 Hipotézisek, próbák

Vegyünk a \mathcal{P} valószínűségi mértékek osztályát. Legyen ez felbontható \mathcal{P}_0 és \mathcal{P}_1 diszjunkt részhalmazokra. Állítsunk fel egy véletlen eseményhez tartozó \mathcal{P} valószínűségi mértékre egy H_0 nullhipotézist, és egy H_1 alternatív hipotézist,

annak értelmében, hogy a P a \mathcal{P}_0 vagy \mathcal{P}_1 halmaz eleme. A döntést, hogy P melyikhez tartozik a statisztikai minta alapján hozzuk. Készítünk egy próbatasztisztikát, ami hogyha teljesül, akkor H_0 -át fogadjuk el, ellenkező esetben H_1 -et. Elsőfajú hibát követünk el, ha helyes nullhipotézist elvetjük, és másodfajút, ha a helytelent elfogadjuk.

A következőkben különböző próbákat fogunk vizsgálni, melyekben a nullhipotézis elfogadásának eldöntésére előre definiált próbatasztisztikák állnak rendelkezésünkre.

17.2.1 Paraméteres próbák

- Egymintás u próba:

Legyen egy m és D paraméterű normális eloszlásból vett mintánk. D értéke ismert, m -é nem. A nullhipotézis ebben az esetben, hogy az eloszlás várható értéke éppen m , jelben

$$H_0 : EX = m$$

$$H_1 : EX \neq m$$

Próbatasztisztikánk az

$$\left| \frac{\bar{x}_n - m}{D} \sqrt{n} \right|$$

Ha ennek értéke kisebb mint u_ε (ahol $\Phi(u_\varepsilon) = 1 - \frac{\varepsilon}{2}$) akkor H_0 -t elfogadjuk, máskülönben elvetjük.

- Kétmintás u próba:

Legyenek m_1 és D_1 valamint m_2 és D_2 paraméterű normális eloszlásból vett mintánk. D -k ismertek, m -ek nem. A nullhipotézis ebben az esetben, hogy a két eloszlás várható értéke megegyezik, jelben

$$H_0 : m_1 = m_2$$

$$H_1 : m_1 \neq m_2$$

Próbatasztisztikánk az

$$\left| \frac{\bar{x}_n - \bar{y}_k}{\sqrt{\frac{D_1^2}{n} + \frac{D_2^2}{k}}} \right|$$

Ha ennek értéke kisebb mint u_ε (ahol $\Phi(u_\varepsilon) = 1 - \frac{\varepsilon}{2}$) akkor H_0 -t elfogadjuk, máskülönben elvetjük.

- Egymintás t próba:

Legyen egy m és D paraméterű normális eloszlásból vett mintánk. D és m értéke is ismeretlen. A nullhipotézis ebben az esetben, hogy a eloszlás várható értéke éppen m , jelben

$$H_0 : EX = m$$

$$H_1 : EX \neq m$$

Próbastatisztikánk az

$$\frac{\bar{x}_n - m}{s_n^{*2}} \sqrt{n} \in t_{n-1}$$

Ha ennek abszolút értéke kisebb mint t_ε (ahol t_ε -t a Student-eloszlás táblázatából tudjuk kiolvasni) akkor H_0 -t elfogadjuk, máskülönben elvetjük.

- Kétmintás t próba:

Legyenek m_1 és D valamint m_2 és D paraméterű normális eloszlásból vett mintánk. A közös D és m sem nem. A nullhipotézis ebben az esetben, hogy a két eloszlás várható értéke megegyezik, jelben

$$H_0 : m_1 = m_2$$

$$H_1 : m_1 \neq m_2$$

Próbastatisztikánk az

$$\frac{\frac{\bar{x}_n - \bar{y}_k}{D\sqrt{\frac{1}{n} + \frac{1}{k}}}}{\sqrt{\frac{(n-1)s_{x,n}^{*2}}{D^2} + \frac{(k-1)s_{y,k}^{*2}}{D^2}}} = \frac{\bar{X}_n - \bar{Y}_k}{\sqrt{(n-1)s_{x,n}^{*2} + (k-1)s_{y,k}^{*2}}} \in t_{n+k-2}$$

Ha ennek abszolút értéke kisebb mint t_ε (ahol t_ε -t az $n+k-2$ szabadságfokú Student táblázatból tudjuk kiolvasni, az $1-k$ -hoz tartozó érték.) akkor H_0 -t elfogadjuk, máskülönben elvetjük.

- F próba:

Legyen adott két mintánk, m_1, D_1 , illetve m_2, D_2 paraméterű normális eloszlásból. Egyik érték sem ismert. A nullhipotézis ebben az esetben, hogy a két eloszlás szórása megegyezik, jelben

$$H_0 : D_1 = D_2$$

$$H_1 : D_1 \neq D_2$$

Próbastatisztikánk az

$$\frac{s_{x,n}^{*2}}{s_{y,k}^{*2}}$$

Ha ennek értéke K_1 és K_2 közé esik, ahol a két értéket az $n-1, k-1$ szabadságfokú Fisher táblából kapjuk, akkor elfogadjuk H_0 -át, egyébként elvetjük.

Mind az 5 próbastatisztika elsőfajú hibaválósínúsége ε -nal egyenlő.