

1. Ismeretlen m várható értékű, 1 szórájú normális eloszlásból a következő hatelemű mintát kaptuk:

$$2,48 \quad 3,3 \quad 1,83 \quad 0,1 \quad 1,32 \quad 2,97$$

- a) Számítsuk ki a mintaközepet és a tapasztalati szórásnégyzetet! (8 pont)
 b) Tegyük fel, hogy X normális eloszlású valószínűségi változó, melynek várható értéke az a) feladatban meghatározott mintaközép, szórásnégyzete pedig 1. Határozzuk meg annak valószínűségét, hogy $X < 3$! (6 pont)

2. Ismeretlen $b > 0$ paraméterű Poisson-eloszlásból származó független X_1, X_2, \dots, X_n minta esetén jelölje \bar{X} a mintaközepet, s_n^{*2} pedig a korrigált tapasztalati szórásnégyzetet. Milyen $0 < r < 1$ számokra igaz, hogy

$$T(X_1, X_2, \dots, X_n) = r \cdot \bar{X} + (1 - r) \cdot s_n^{*2}$$

torzítatlan becslése a b paraméternek? (12 pont)

3. Legyen X_1, X_2, \dots, X_n független minta a következő diszkrét eloszlásból:

$$P(X_i = 1) = b, \quad P(X_i = 2) = \frac{1}{2} - 3b, \quad P(X_i = 4) = \frac{1}{2} + 2b, \quad i = 1, 2, \dots, n,$$

ahol $0 \leq b \leq \frac{1}{6}$ az ismeretlen paraméter. Adjunk becslést a b paraméterre momentum-módszerrel! (12 pont)

4. $a > 0$ esetén legyen az $f_a(x)$ sűrűségfüggvény a következő:

$$f_a(x) = \begin{cases} a^2 \cdot x \cdot e^{-ax} & \text{ha } x > 0, \\ 0 & \text{különben.} \end{cases}$$

Legyen X_1, X_2, \dots, X_n független minta az $f_a(x)$ sűrűségfüggvényhez tartozó eloszlásból, ahol $a > 0$ ismeretlen paraméter. Határozzuk meg az a paraméter maximum likelihood becslését! (12 pont)

Beadható feladat: Legyen X_1, X_2, \dots független minta az $[\frac{a}{2}, \frac{3a}{2}]$ intervallumon egyenletes eloszlásból, ahol $a > 0$ ismeretlen paraméter. Igaz-e, hogy a mintaközép konzisztens becslése az a paraméternek?

A megoldásokat indokolni kell, a teljes pontszámhoz jó végeredmény és helyes indoklás szükséges. Összesen 50 pontot lehet elérni, az egyes feladatokért kapható pontszámok a feladat szövege mellett szerepelnek. A várható pontszámok: 40, 61, 72, 83.

Az elégséges határa 20 pont, aki ezt nem éri el vagy a dolgozatot nem írja meg, szorgalmi időszak utolsó hetében vagy a vizsgaidőszak első hetében pótolhatja a dolgozatot.

Az eredmények az ETR infosheet rovatában lesznek elérhetők, a megoldásokat pedig a <http://www.cs.elte.hu/~agnes/gyak> címen lehet majd megtalálni.

Mintaközép/tapasztalati közép: $\bar{X} = \frac{1}{n} (X_1 + X_2 + \dots + X_n)$

Tapasztalati szórásnégyzet:

$$s^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2$$

Tapasztalati szórás:

$$s = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2}$$

Korrigált tapasztalati szórásnégyzet:

$$s_n^{*2} = \frac{n}{n-1} \left[\frac{1}{n} \left(\sum_{i=1}^n X_i^2 \right) - \bar{X}^2 \right]$$

Szórási együttható:

$$c = \frac{s}{\bar{X}}$$

Tapasztalati eloszlásfüggvény:

$$\hat{F}(t) = \frac{1}{n} \sum_{i=1}^n I(X_i < t) = \frac{1}{n} |\{i : X_i < t\}|$$

Ha X_1, X_2, \dots, X_n független minta valamely véges szórású eloszlásból, akkor: $E(\bar{X}) = EX_1$, $D^2(\bar{X}) = \frac{1}{n} D^2(X_1)$, és $E(s_n^{*2}) = D^2(X_1)$.

$a > 0$ paraméterű *exponenciális* eloszlás eloszlásfüggvénye: $F(t) = 1 - e^{-at}$, ha $t \geq 0$, különben 0; sűrűségfüggvénye: $f(t) = ae^{-at}$, ha $t \geq 0$, különben 0; várható értéke: $\frac{1}{a}$; szórásnégyzete: $\frac{1}{a^2}$.

$b > 0$ paraméterű *Poisson-eloszlás*: $p_k = \frac{b^k}{k!} e^{-b}$; várható értéke: b ; szórásnégyzete: b .

$[a, b]$ intervallumon *egyenletes* eloszlás eloszlásfüggvénye:

$F(t) = \frac{t-a}{b-a}$, ha $a \leq t \leq b$, 0, ha $t \leq a$, 1 különben;

sűrűségfüggvénye: $f(t) = \frac{1}{b-a}$, ha $a \leq t \leq b$, 0 különben; várható értéke: $\frac{a+b}{2}$; szórásnégyzete: $\frac{(b-a)^2}{12}$.

Binomiális eloszlás $n \geq 1$ és $0 < p < 1$ paraméterekkel: $p_k = \binom{n}{k} p^k (1-p)^{n-k}$; várható értéke: $n \cdot p$; szórásnégyzete: $n \cdot p \cdot (1-p)$.

$N(m, \sigma^2)$ *normális* eloszlás sűrűségfüggvénye: $f(x) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(x-m)^2}{2\sigma^2}\right)$;

várható értéke: m , szórásnégyzete: σ^2 . Eloszlásfüggvény táblázata a lap másik oldalán.

$0 < p < 1$ paraméterű *geometriai* eloszlás: $p_k = (1-p)^{k-1} \cdot p$;

várható értéke: $\frac{1}{p}$, szórásnégyzete: $\frac{1-p}{p^2}$.

Megoldások

1. a) Legyen a minta X_1, X_2, \dots, X_6 , ekkor a mintaközép:

$$\bar{X} = \frac{1}{6} (X_1 + X_2 + \dots + X_6) = \frac{1}{6} (2, 48 + 3, 3 + 1, 83 + 0, 1 + 1, 32 + 2, 97) = 2.$$

A tapasztalati szórásnégyzet:

$$s^2 = \frac{1}{6} \sum_{i=1}^6 X_i^2 - \bar{X}^2 = \frac{1}{6} (2, 48^2 + 3, 3^2 + 1, 83^2 + 0, 1^2 + 1, 32^2 + 2, 97^2) - 2^2 \approx 1, 1604.$$

b) Az előző szerint tehát $X \sim N(2, 1)$, azaz X normális eloszlású 2 várható értékkel és 1 szórással. Ekkor az $X - 2$ valószínűségi változó normális eloszlású 0 várható értékkel és 1 szórással, azaz eloszlása standard normális, így

$$P(X < 3) = P(X - 2 < 1) = \Phi(1) \approx 0, 8413$$

a standard normális eloszlásfüggvény táblázata alapján.

2. Gyakorlaton szerepelt, hogy tetszőleges véges szórású eloszlásból származó X_1, \dots, X_n független minta esetén a mintaközép várható értéke $E(X_1)$, a korrigált tapasztalati szórásnégyzet várható értéke pedig $D^2(X_1)$. A Poisson-eloszlás tetszőleges $b > 0$ paraméter mellett véges szórású, így alkalmazhatjuk ezeket az összefüggéseket. Felhasználva még a várható érték linearitását, azt kapjuk, hogy minden $b > 0$ -ra

$$E_b(r \cdot \bar{X} + (1 - r) \cdot s_n^{*2}) = r \cdot E_b(\bar{X}) + (1 - r) E_b(s_n^{*2}) = r \cdot E_b(X_1) + (1 - r) D_b^2(X_1).$$

b paraméterű Poisson-eloszlás várható értéke és szórásnégyzete is b , tehát a b paraméter mellett X_1 várható értéke és szórásnégyzete is b . Azaz

$$E_b(T(X_1, \dots, X_n)) = r \cdot E_b(X_1) + (1 - r) D_b^2(X_1) = r \cdot b + (1 - r) \cdot b = b.$$

Tehát minden $0 < r < 1$ számra minden $b > 0$ paraméterre $E_b(r \cdot \bar{X} + (1 - r) \cdot s_n^{*2}) = b$, azaz minden $0 < r < 1$ számra $r \cdot \bar{X} + (1 - r) \cdot s_n^{*2}$ torzítatlan becslése a b paraméternek.

3. Egyetlen paramétert kell becsülnünk, így használjuk az első momentumot, a várható értéket. A várható érték definíciója szerint tetszőleges $i = 1, 2, \dots, n$ -re

$$\begin{aligned} E(X_i) &= 1 \cdot P(X_i = 1) + 2 \cdot P(X_i = 2) + 4 \cdot P(X_i = 4) = \\ &= b + 2 \cdot \left(\frac{1}{2} - 3b\right) + 4 \cdot \left(\frac{1}{2} + 2b\right) = b + 1 - 6b + 2 + 8b = 3 + 3b. \end{aligned}$$

A tapasztalati eloszlás várható értéke a mintaközép. Tehát a b paraméter momentum-módszerrel kapott becslése az a b szám lesz, melyre

$$\bar{X} = E(X_1) = 3 + 3b.$$

Átrendezve adódik a b becslése:

$$\hat{b} = \frac{\bar{X} - 3}{3}.$$

4. Mivel adott a sűrűségfüggvény, folytonos eloszlások családjáról van szó, így a likelihood-függvényt úgy kapjuk, hogy az egyes mintaelemeket behelyettesítjük az adott paraméterhez tartozó sűrűségfüggvénybe, és ezeket összeszorozzuk. A paraméter minden értékére a negatív számokon a sűrűségfüggvény nulla, így 1 valószínűséggel minden mintaelem pozitív, vagyis:

$$f(a) = \prod_{i=1}^n f_a(X_i) = \prod_{i=1}^n (a^2 \cdot X_i \cdot e^{-aX_i}).$$

A maximum likelihood becslés az az $a > 0$ szám lesz, melyre $f(a)$ maximális. $f(a)$ minden a -ra pozitív, és a logaritmusfüggvény monoton növekvő, így elég a log-likelihood függvényt maximalizálni. A log-likelihood függvény a likelihood függvény logaritmusa, szorzat logaritmusa pedig a logaritmusok összege:

$$\begin{aligned} l(a) &= \sum_{i=1}^n \log(a^2 \cdot X_i \cdot e^{-aX_i}) = \\ &= \sum_{i=1}^n (\log a^2 + \log X_i - aX_i) = \\ &= 2n \log a + \sum_{i=1}^n \log X_i - a \sum_{i=1}^n X_i. \end{aligned}$$

Ez a -nak folytonosan differenciálható függvénye. Ha $a \rightarrow 0+$, akkor az első tag $-\infty$ -hez tart, a második konstans, a harmadik nullához tart, azaz ilyenkor $l(a) \rightarrow -\infty$. Ha $a \rightarrow \infty$, akkor az első tag végtelenhez tart logaritmikusan, a második tag konstans, a harmadik tag $-\infty$ -hez tart lineárisan, így ilyenkor $l(a) \rightarrow -\infty$. Mindezekből következik, hogy $l(a)$ -nak van maximuma, és ott a deriváltja nulla. Tekintsük tehát a log-likelihood egyenletet: $l'(a) = 0$, azaz

$$\frac{2n}{a} - \sum_{i=1}^n X_i = 0.$$

Ennek egyetlen megoldása van, amit átrendezéssel kaphatunk meg: $a = \frac{2n}{\sum_{i=1}^n X_i} = \frac{2}{\bar{X}}$. Tehát ez az a maximalizálja a log-likelihood és likelihood függvényeket, azaz a maximum likelihood becslése:

$$\hat{a} = \frac{2n}{\sum_{i=1}^n X_i} = \frac{2}{\bar{X}}.$$

1. A strandon figyeljük, hogy ki mennyi időt tölt a tóban fürdéssel, és feltételezzük, hogy az egyes emberek vízben töltött ideje egymástól független, eloszlásuk pedig a következő sűrűségfüggvénnyel adható meg:

$$f(x) = \frac{1}{2} \cdot a^3 \cdot x^2 \cdot e^{-ax}, \text{ ha } x > 0, \text{ és } 0 \text{ különben,}$$

ahol $a > 0$ ismeretlen paraméter. Számítsuk ki n ember vízben töltött idejének megfigyeléséből adódó Fisher-információt. Ehhez felhasználhatjuk, hogy a fent megadott eloszlás várható értéke $\frac{3}{a}$, szórásnégyzete $\frac{3}{a^2}$. (9 pont)

2. Az Esterházy-kastélyban pihenő vendégek szokásait szeretnénk feltérképezni. Feltételezésünk, hogy a vendégek egymástól függetlenül $p = 1/4$ valószínűséggel töltik alvással a délutánt. Megkérdezzük 10 véletlenszerűen kiválasztott vendéget, és ha közülük legalább 9-en szoktak délután aludni, akkor elvetjük a nullhipotézisünket, különben elfogadjuk. Számítsuk ki az elsőfajú hiba valószínűségét! (9 pont)
3. A közeli település híres pincéinek egyikében szürkebarát és olaszrizling borokat vizsgáltak. Mindkét fajtából 7-7 pohárban megmérték a cukortartalmat, g/l -ben kifejezve a következő értékek adódtak:

szürkebarát	13,1	12,5	13,0	14,0	13,5	12,6	13,4
olaszrizling	13,6	12,7	12,3	11,9	13,4	12,8	12,0

Legyen nullhipotézisünk az, hogy a kétféle bor átlagos cukortartalma megegyezik, ellenhipotézisünk az, hogy a szürkebaráté nagyobb. Ezt a feladatot vizsgálva $\alpha = 0,03$ terjedelem mellett döntünk arról a feltételezésről, hogy az olaszrizling nem édesebb a szürkebarátnál! (9 pont)

4. A parton a nádas átlagos magasságát vizsgálták. 5 szálát véletlenszerűen kiválasztottak, ezek vízszint feletti magassága méterben:

1,43	1,55	1,58	1,64	1,44
------	------	------	------	------

$\alpha = 0,05$ terjedelem mellett elfogadható-e az a feltételezés, hogy az átlagos magasság legfeljebb másfél méter? (9 pont)

5. A XIII. században alapított vár köveit vizsgálták színük és állapotuk szerint. Világos kőből 105-t, sötétből 91-t találtak. A világosak közül 61, a sötétek közül 48 volt ép, a többi sérült.
- a) $\alpha = 0,01$ terjedelem mellett elfogadható-e, hogy a szín és az állapot egymástól független?
- b) $\alpha = 0,01$ terjedelem mellett elfogadható-e a következő feltételezés: a szín és az állapot egymástól független, minden kő $1/2 - 1/2$ valószínűséggel sötét vagy világos, és szintén $1/2 - 1/2$ valószínűséggel ép vagy sérült? (14 pont)

A megoldásokat indokolni kell, a teljes pontszámhoz jó végeredmény és helyes indoklás szükséges. Összesen 50 pontot lehet elérni, az egyes feladatokért kapható pontszámok a feladat szövege mellett szerepelnek. A várható pontszámok: 40, 61, 72, 83.

Az elégséges határa 20 pont, aki ezt nem éri el vagy a dolgozatot nem írja meg, szorgalmi időszak utolsó hetében vagy a vizsgaidőszak első hetében pótolhatja a dolgozatot, ennek időpontját később egyeztetjük, erről a kurzusfórumban lehet elolvasni.

Az eredmények és a megajánlott jegyek az ETR infosheet rovatában lesznek elérhetők, a megoldásokat pedig a <http://www.cs.elte.hu/~agnes/gyak> címen lehet majd megtalálni.

1. A megfigyeléseket jelölje X_1, \dots, X_n , ezek tehát független, azonos eloszlású valószínűségi változók a megadott sűrűségfüggvénnyel. Folytonos eloszlásokról van szó, hiszen létezik sűrűségfüggvény, így n elemű mintából számolva a likelihood-függvény:

$$f(a) = \prod_{i=1}^n f(X_i) = \prod_{i=1}^n \left[\frac{1}{2} \cdot a^3 \cdot X_i^2 \cdot e^{-aX_i} \right] = \left(\frac{1}{2} \right)^n \cdot a^{3n} \cdot \left(\prod_{i=1}^n X_i^2 \right) \cdot e^{-\sum_{i=1}^n aX_i}.$$

Ennek logaritmus a log-likelihood függvény:

$$l(a) = n \log \left(\frac{1}{2} \right) + 3n \log a + \log \left(\prod_{i=1}^n X_i^2 \right) - a \sum_{i=1}^n X_i.$$

Az a paraméter szerint deriválva:

$$\frac{d}{da} l(a) = \frac{3n}{a} - \sum_{i=1}^n X_i.$$

A Fisher-információt megkaphatjuk úgy, hogy ennek a mennyiségnek kiszámítjuk a szórásnégyzetét az a paraméterhez tartozó sűrűségfüggvénnyel kapható mintából. Az első tag konstans, véletlentől nem függ, így levonva a szórásnégyzet nem változik. -1 -gyel szorozva sem változik a szórásnégyzet. Tehát független valószínűségi változók összegének szórásnégyzete jelenik meg, ez a szórásnégyzetek összege, most $D^2(X_1)$ n -szerese, hiszen azonos eloszlású valószínűségi változókról van szó. A feladatban szerepel, hogy az a -hoz tartozó eloszlás szórásnégyzete $3/a^2$, így ez lesz X_1 szórásnégyzete is. Összefoglalva:

$$\begin{aligned} I(a) &= D_a^2 \left(\frac{d}{da} l(a) \right) = D_a^2 \left(\frac{3n}{a} - \sum_{i=1}^n X_i \right) = D_a^2 \left(\sum_{i=1}^n X_i \right) = \\ &= \sum_{i=1}^n D_a^2(X_i) = n D_a^2(X_1) = n \frac{3}{a^2}. \end{aligned}$$

2. Nullhipotézisünk, hogy minden vendég egymástól függetlenül p valószínűséggel alszik délután. Az elsőfajú hiba a nullhipotézis melletti valószínűsége annak, hogy hibás döntést hozunk, azaz elvetjük a nullhipotézist. A nullhipotézist akkor vetjük el, ha a tíz megkérdezett ember közül leglább kilencen alszanak délután. Az elsőfajú hiba valószínűsége tehát annak valószínűsége, hogy tíz ember közül legalább kilencen alszanak délután, feltételezve, hogy mindenki egymástól függetlenül p valószínűséggel alszik délután. A binomiális eloszlás megfelelő tagjaiból adódik ennek értéke:

$$p^{10} + 10 \cdot p^9 \cdot (1 - p).$$

Az első tag ugyanis annak valószínűsége, hogy mind a tízen alszanak, a második annak, hogy pontosan kilencen alszanak, tehát az összeg adja az elsőfajú hiba valószínűségét. $p = 1/3$ -ra ez körülbelül $3,56 \cdot 10^{-4}$, $p = 1/4$ -re körülbelül $2,96 \cdot 10^{-5}$.

3. Feltételezzük, hogy az egyes borok cukortartalma normális eloszlású, és a szórások megegyeznek. A szürkebarát cukortartalmának eloszlása $N(m_1, \sigma)$, az olaszrizlingének pedig $N(m_2, \sigma)$. Ezekkel a jelölésekkel:

$$H_0 : m_1 = m_2$$

$$H_1 : m_1 > m_2$$

Tehát a hipotézisvizsgálati feladat normális eloszlások várható értékének összehasonlításáról szól, a szórások nem ismertek, de egyenlőnek feltételezhetők, továbbá feltételezhetjük, hogy két független mintával van dolgunk. Ezért kétmintás t -próbát végzünk. Kiszámítjuk a próbastatisztikát:

$$t = \sqrt{\frac{mn(m+n-2)}{m+n}} \frac{\bar{X} - \bar{Y}}{\sqrt{(n-1)s_n^{*2}(X) + (m-1)s_m^{*2}(Y)}}.$$

Ennek értéke a különböző adatsorokra különböző. A próbastatisztika eloszlása H_0 mellett $n+m-2$ szabadságfokú t -eloszlás, ahol n és m az egyes minták elemszáma, azaz $n = m = 7$, a szabadságfok pedig 12. Tehát a kritikus érték 12 szabadságfokú t -eloszláshoz és $\alpha = 0,05$ terjedelemhez tartozó egyoldali kritikus érték:

$$c_{krit} = 1,782.$$

Tehát a próbánk a következő:

Ha $t \leq 1,782$, akkor elfogadjuk H_0 -t, és ezt úgy értelmezzük, hogy vagy az olaszrizling legalább olyan édes, mint a szürkebarát, vagy nincs elég adatunk ahhoz, hogy ezt megcáfoljuk. Ha $t > 1,782$, akkor elvetjük H_0 -t, és ezt úgy értelmezzük, hogy statisztikai bizonyítékot nyertünk arra, hogy a szürkebarát édesebb az olaszrizlingnél.

4. Feltételezzük, hogy a nádszálak magassága $N(m, \sigma)$ eloszlású. A következő feladatot vizsgáljuk:

$$H_0 : m \leq 1,5$$

$$H_1 : m > 1,5$$

Normális eloszlás várható értékről szól a hipotézisvizsgálati feladat, és a szórás nem ismert, ezért egymintás t -próbát végzünk. Kiszámítjuk a próbastatisztikát:

$$t = \sqrt{n} \frac{\bar{X} - m_0}{s_n^*}.$$

H_0 mellett a próbastatisztika $n-1$ szabadságfokú t -eloszlás, ahol n a minta elemszáma, azaz 5. Egyoldali ellenhipotéziünk van, ezért a kritikus érték a 4 szabadságfokú t -eloszláshoz és $\alpha = 0,05$ terjedelmhez tartozó egyoldali kritikus érték:

$$c_{krit} = 2,132.$$

A próbánk a következő:

Ha $t \leq 2,132$, akkor elfogadjuk H_0 -t, azaz elfogadható az a feltételezés, hogy a nádas átlagos magassága legfeljebb másfél méter.

Ha $t > 2,132$, akkor elvetjük H_0 -t, és statisztikai bizonyítékunk van arra, hogy a nádas átlagos magassága több másfél méternél, a feltételezés nem fogadható el.

5. a) Az adatokat az alábbi táblázatban foglalhatjuk össze:

	ép	sérült	összesen
világos	61	44	105
sötét	48	43	91
összesen	109	87	196

Függetlenségvizsgálatot végzünk, a nullhipotézis az, hogy a két szempont szerinti osztályozás egymástól független, ellenhipotézis, hogy nem független. Végezhetünk χ^2 -próbát osztályok összevonása nélkül, mert minden osztályba esik legalább 5 megfigyelés. Mindkét

szempont szerint két osztály van, $r = s = 2$, és így a próbastatisztika az órán használt jelölésekkel:

$$n \frac{(\nu_{11}\nu_{22} - \nu_{12}\nu_{21})^2}{\nu_{1.}\nu_{2.}\nu_{.1}\nu_{.2}} = 196 \cdot \frac{(61 \cdot 43 - 44 \cdot 48)^2}{105 \cdot 91 \cdot 109 \cdot 87} \approx 0,565.$$

A kritikus érték az 1 szabadságfokú χ^2 -próbaához tartozó kritikus érték, $\alpha = 0,1$ terjedelem mellett 2,71, $\alpha = 0,05$ terjedelem mellett 3,84, végül $\alpha = 0,01$ terjedelem mellett 6,63. Mindhárom esetben $\chi^2 < c_{krit}$, ezért elfogadjuk a nullhipotézist, azaz elfogadható az a feltételezés, hogy a szín és állapot szerinti osztályozás egymástól független, az adatok ezt nem cáfolják.

b) A köveket négy osztályba sorolták:

	ép és világos	ép és sötét	sérült és világos	sérült és sötét
darab	61	48	44	43

A következő feltételezést vizsgáljuk: a szín és az állapot egymástól független, minden kő $1/2 - 1/2$ valószínűséggel sötét vagy világos, és szintén $1/2 - 1/2$ valószínűséggel ép vagy sérült. Ezek együttesen azt jelentik, hogy minden kő a négy osztály mindegyikébe $1/4 - 1/4$ valószínűséggel esik, tehát illeszkedésvizsgálatot végzünk, a nullhipotézis, hogy minden osztályba $1/4$ valószínűséggel esnek a kövek, az ellenhipotézis, hogy az eloszlás ettől különböző.

Most sem kell osztályokat összevonni. A próbastatisztika:

$$\sum_{i=1}^r \frac{(\nu_i - np_i)^2}{np_i} = \frac{(61 - 49)^2}{49} + \frac{(48 - 49)^2}{49} + \frac{(44 - 49)^2}{49} + \frac{(43 - 49)^2}{49} \approx 1,051.$$

r az osztályok száma, azaz 4, így az $r - 1 = 3$ szabadságfokú χ^2 -eloszlás kritikus értékét kell megkeresnünk. $\alpha = 0,1$ terjedelem mellett 6,25, $\alpha = 0,05$ terjedelem mellett 7,81, végül $\alpha = 0,01$ terjedelem mellett 11,3. Mindhárom esetben $\chi^2 < c_{krit}$, ezért elfogadjuk a nullhipotézist, azaz elfogadható a fenti feltételezés, az adatok ezt nem cáfolják.

Mintaközép/tapasztalati közép: $\bar{X} = \frac{1}{n} (X_1 + X_2 + \dots + X_n)$

Tapasztalati szórásnégyzet:

$$s^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2$$

Tapasztalati szórás:

$$s = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2}$$

Korrigált tapasztalati szórásnégyzet:

$$s_n^{*2} = \frac{n}{n-1} \left[\frac{1}{n} \left(\sum_{i=1}^n X_i^2 \right) - \bar{X}^2 \right]$$

X_1, \dots, X_n független minta esetén a likelihood-függvény:

$f(\theta) = \prod_{i=1}^n f_\theta(X_i)$, ha a minta folytonos eloszlásból származik, és $f_\theta(x)$ a θ paraméterhez tartozó sűrűségfüggvény;

$f(\theta) = \prod_{i=1}^n P_\theta(\xi = X_i)$, ha a minta diszkrét eloszlásból származik, ahol ξ eloszlása megegyezik X_1 eloszlásával, és független a mintától.

A log-likelihood függvény: $l(\theta) = \log f(\theta)$.

A minta Fisher-információja: $I(\theta) = E_\theta \left[\left(\frac{d}{d\theta} l(\theta) \right)^2 \right] = D_\theta^2 \left(\frac{d}{d\theta} l(\theta) \right)$ megfelelő feltételek mellett. Megfelelő regularitási feltételek mellett n elemű független minta Fisher-információja az egyelemű minta Fisher-információjának n -szereese.

$N(m, \sigma)$ normális eloszlásból származó X_1, \dots, X_n független minta esetén legyen u_y olyan, hogy $\Phi(u_y) = y$. Ekkor

$$P \left(\bar{X} - u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \leq m \leq \bar{X} + u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \right) \geq 1 - \alpha.$$

$X_1, X_2, \dots, X_n, Y_1, Y_2, \dots, Y_m$ független normális eloszlású minták

u-próba

Egymintás esetben $H_0 : m = m_0$ nullhipotézis mellett

$$u = \sqrt{n} \frac{\bar{X} - m_0}{\sigma} \sim N(0, 1).$$

Kétmintás esetben $H_0 : m_1 = m_2$ nullhipotézis mellett

$$u = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}} \sim N(0, 1).$$

t-próba

Egymintás esetben $H_0 : m = m_0$ nullhipotézis mellett

$$t = \sqrt{n} \frac{\bar{X} - m_0}{s_n^*} \sim t_{n-1}.$$

Kétmintás esetben $H_0 : m_1 = m_2$ nullhipotézis mellett

$$t = \sqrt{\frac{mn(m+n-2)}{m+n}} \frac{\bar{X} - \bar{Y}}{\sqrt{(n-1)s_n^{*2}(X) + (m-1)s_m^{*2}(Y)}} \sim t_{n+m-2}.$$

F-próba

$H_0 : \sigma_1^2 = \sigma_2^2$ nullhipotézis mellett

$$F = \frac{s_n^{*2}(X)}{s_m^{*2}(Y)} \sim F_{n-1, m-1}.$$

χ^2 -próbák

Illeszkedésvizsgálat

A_1, A_2, \dots, A_r teljes eseményrendszer, p_i adott számok, ν_i az A_i gyakorisága n elemű mintából

H_0 : minden i -re $P(A_i) = p_i$

Ekkor H_0 mellett

$$\sum_{i=1}^r \frac{(\nu_i - np_i)^2}{np_i} \rightarrow \chi_{r-1}^2 \quad \text{eloszlásban, ha } n \rightarrow \infty.$$

Becsléses illeszkedésvizsgálat

H_0 mellett

$$\sum_{i=1}^r \frac{(\nu_i - n\hat{p}_i)^2}{n\hat{p}_i} \rightarrow \chi_{r-s-1}^2 \quad \text{eloszlásban, ha } n \rightarrow \infty,$$

ahol s a becsült paraméterek száma

Homogenitásvizsgálat

ν_i illetve μ_i az i . osztály gyakorisága az egyes mintákban. H_0 mellett

$$nm \sum_{i=1}^r \frac{(\nu_i/n - \mu_i/m)^2}{\nu_i + \mu_i} \rightarrow \chi_{r-1}^2 \quad \text{eloszlásban, ha } n \rightarrow \infty.$$

Függetlenségvizsgálat

H_0 mellett

$$n \sum_{i,j} \frac{(\nu_{ij} - \frac{\nu_{i.}\nu_{.j}}{n})^2}{\nu_{i.}\nu_{.j}} \rightarrow \chi_{(r-1)(s-1)}^2 \quad \text{eloszlásban, ha } n \rightarrow \infty.$$

$r = s = 2$ -re

$$n \frac{(\nu_{11}\nu_{22} - \nu_{12}\nu_{21})^2}{\nu_{1.}\nu_{.2}\nu_{.1}\nu_{.2}} \rightarrow \chi_1^2$$

A χ^2 -próba kritikus értékei

f	0,1	0,05	0,01
1	2,71	3,84	6,63
2	4,61	5,99	9,21
3	6,25	7,81	11,3
4	7,78	9,49	13,3
5	9,24	11,1	15,1
6	10,6	12,6	16,8
7	12,0	14,1	18,5
8	13,4	15,5	20,1
9	14,7	16,9	21,7