

# Valószínűségelméleti és matematikai statisztikai alapfogalmak összefoglalása

(Kemény Sándor - Deák András: Mérések tervezése és eredményeik értékelése, kivonat)

Véletlen jelenség: okok rendszere hozza létre - nem ismerhetjük mind, ezért sztochasztikus.

Véletlen hiba: figyelembe nem vett, egyenként kis hatású változók ingadozásainak összessége, a hiba átlagértéke a mérési szám növelésével nullához tart.

Sokaság és minta: pl. sörösüvegek milliói... De ez véges sokaság - végtelen sokaság pl. egy tömegmérés eredménye.

Mérés: a sokaság egy elemének kiválasztása, véges számmal ismételve az lesz a minta, a mérés mintavétel.

Valószínűségi változó: értéke nem állandó, bizonyos valószínűséggel esik adott határok közé. (lehet diszkrét - folytonos)

## *Relatív gyakoriság és valószínűség*

Vett minta  $\mapsto$  sokaság eloszlása.

végtelen sokaság: relatív gyakoriság megfelelője a valószínűség

(relatív gyakoriság: előfordulások száma osztva az összes érték előfordulásának számával)

végtelen sok mérésnél a minta azonos a sokasággal. Ekkor a relatív gyakoriság = valószínűség.


A valószínűség a relatív gyakoriság határértéke  $\infty$  minta esetén.

## *Folytonos valószínűségi változó sűrűség- és eloszlásfüggvénye*

Osztályba sorolás:  $\Delta x$  az osztály szélessége,  $x_i$  az osztály közepe, az osztályindex

Téglalapok területe  $\sim$  intervallumba eső elemek számával  $n_i$

Területek összege  $\sim$  minta elemszámával ( $N$ )




1. ábra. A gyakorisági hisztogram

Relatív gyakorisági hisztogram: a téglalapok területe osztva az összterülettel  $\frac{n_i}{N}$   
 A terület összege 1!

Első esetben a magasság  $\sim \frac{n_i}{\Delta x}$ , második esetben  $\sim \frac{n_i}{(N\Delta x)}$ .

Ha  $N \rightarrow \infty$  (növeljük a minta elemszámát), és az osztályok szélességét csökkentjük ( $\Delta x \rightarrow 0$ )  
 a valószínűség sűrűségfüggvényt kapjuk meg:



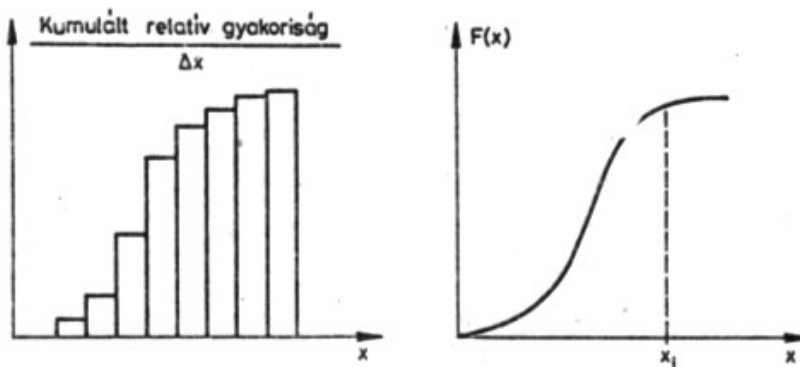
2. ábra. Valószínűség sűrűségfüggvény

$$\lim_{N \rightarrow \infty, \Delta x \rightarrow 0} \frac{\text{rel. gyak.}}{\Delta x} = f(x) \quad (1)$$

Értelmezése:

$$P(x_0 < x < x_0 + \Delta x) = \int_{x_0}^{x_0 + \Delta x} f(x) dx \approx f(x_0) \Delta x \quad (2)$$

Kumulatív relatív gyakoriság: a valószínűségi változó  $x_i$  vagy annál kisebb értéket vesz fel.



3. ábra.

$$\lim_{N \rightarrow \infty} \frac{\text{kum. rel. gyak.}}{\Delta x} = F(x) \quad (3)$$

$F(x)$  az eloszlásfüggvény!

$$F(x_i) = \int_{-\infty}^{x_i} f(x)dx \quad (4)$$

Értelmezése:

$$F(x_i) = P(x \leq x_i) \quad (5)$$

$$F(\infty) = \int_{-\infty}^{+\infty} f(x)dx = 1 \quad (6)$$

$F(x)$ ,  $f(x)$  ismerete a sokaság ismeretét jelenti!

*A várható érték ( $E(x)$  is használatos)*

$$M[x] = \int_{-\infty}^{+\infty} xf(x)dx = \mu \quad (7)$$

A sokaság várható értéke megegyezik a valódi értékkel - ha nincs rendszeres hiba.

$$M[\phi(x)] = \int_{-\infty}^{+\infty} \phi(x)f(x)dx \quad (8)$$

$$M[c \cdot x] = c \cdot M[x]; M[c] = c \quad (9)$$

$$M[x_1 + x_2 + \dots + x_k] = M[x_1] + M[x_2] + \dots + M[x_k] \quad (10)$$

Minél inkább igaz, hogy a relatív gyakoriság egyenlő a valószínűséggel, annál jobban megközelíti  $\bar{x}$  a várható értéket.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (11)$$

*A medián:* az az érték, amelynél nagyobbat a valószínűségi változó ugyanolyan valószínűséggel vesz fel, mint kisebbet:

$$F(\mu_e) = \frac{1}{2} \quad (12)$$

Tapasztalati medián: sorba rendezve a középső érték, páratlan elemszám esetében a két középső átlaga!

Tekintsük példának okáért a következő számsorozatot, amelyek akár mérési sorozatot is reprezentálhatnak:

**51, 49, 50, 52, 48, 51, 250, 49, 52,**

ahol a hetedik érték szemmel láthatólag erősen kilóg a többi pont közül, amelyet nyugodtan tekinthetünk mérési hibának is. A különböző módon képzett középértékek a következő eredményeket adják:

aritmetikai:

$$A = \frac{1}{n} \sum_{i=1}^n a_i = 72,44$$

geometriai:

$$G = \sqrt[n]{\prod_{i=1}^n a_i} = 60,03$$

harmonikus:

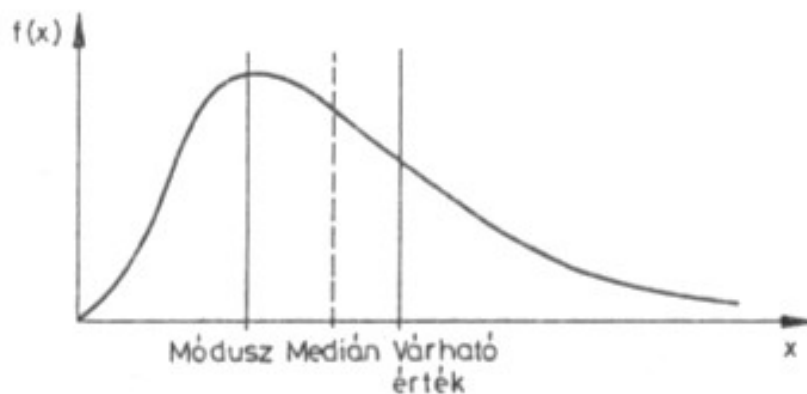
$$H = \frac{n}{\sum_{i=1}^n \frac{1}{a_i}} = 55,10$$

négyzetes:

$$Q = \sqrt{\frac{\sum_{i=1}^n a_i^2}{n}} = 95,86$$

A median eljárás a „valódi” értékhez közelebb eső 51-et fogja szolgáltatni.

A *módusz*: a valószínűségi változók legnagyobb valószínűségű értéke, a sűrűségfüggvény maximumhelye (lehet több is, de ez ritka). A tapasztalati módusz a legnagyobb gyakorisági osztály osztályindexe. Egycsúcsos, szimmetrikus eloszlás esetén a módusz és a medián egybeesik a várható értékkel, egyébként nem feltétlenül.



4. ábra.

A variancia (szórásnégyzet)

$$\text{Var}[x] = \int_{-\infty}^{+\infty} (x - M[x])^2 f(x) dx = \int_{-\infty}^{+\infty} (x - \mu)^2 f(x) dx = M[(x - \mu)^2] \quad (13)$$

Azaz a várható értéktől való eltérés négyzetének várható értéke.  
Jelölés még  $D^2[x]$  és  $\sigma_x^2$ .

$$\text{Var}[x] = M[x^2] - \mu^2; \quad \mu = M[x] \quad (14)$$

Számítástechnikailag jobb kifejezés!

$$\text{Var}[c \cdot x] = c^2 \text{Var}[x] \quad (15)$$

$$\text{Var}[x_1 + x_2 + \dots + x_k] = \text{Var}[x_1] + \text{Var}[x_2] + \dots + \text{Var}[x_k] \quad (16)$$

A szórásnégyzet:

$$s_x^{2*} = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (17)$$


DOF (degrees of freedom): ha tudom a pontos értéket N, ha a méréseinkből származik inkább N-1!

*Normális (Gauss) eloszlás:* sok, egymástól független, egyenként kis hatású tényező hatása adódik össze.

Sűrűség- és eloszlásfüggvénye:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right] \quad (18)$$

$$F(x) = \int_{-\infty}^{+\infty} \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(\xi - \mu)^2}{2\sigma^2}\right] d\xi \quad (19)$$



5. ábra.

Várható értéke és varianciája:

$$M[x] = \mu; \quad \text{Var}[x] = \sigma^2 \quad (20)$$

Szokásos jelölés még:

$$N(\mu, \sigma^2); \quad \text{pl. } N(0, 1) \quad (21)$$

Ha  $F(x)$  értékeit táblázatban akarjuk megadni, 3D-s kellene, mivel  $F(x)$   $\mu$  és  $\sigma^2$  értékeit is tartalmazza! Transzformáció kellene!

*A normalizált (standardizált) normális eloszlás (u-eloszlás)*

Legyen  $u$  egy valószínűségi változó:

$$u = \frac{x - \mu}{\sigma} \quad (22)$$

Ekkor

$$M[u] = M\left[\frac{x - \mu}{\sigma}\right] = \frac{M[x] - \mu}{\sigma} = 0 \quad (23)$$

$$\text{Var}[u] = \text{Var}\left[\frac{x - \mu}{\sigma}\right] = \frac{1}{\sigma^2} \text{Var}[x] = 1 \quad (24)$$

A sűrűségfüggvény

$$f(u) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{u^2}{2}\right) \quad (25)$$

$$P(x \leq a) = F(a) = \int_{-\infty}^a \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left[\frac{x - \mu}{\sigma}\right]^2\right] dx \quad (26)$$



Ez a vonalkázott terület a 6. ábrán!  $u$  definíciójából és mivel  $dx = \sigma du$

$$P(x \leq a) = \int_{-\infty}^{u_a} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{u^2}{2}\right] du = F(u_a) \quad (27)$$

ahol

$$u_a = \frac{a - \mu}{\sigma} \quad (28)$$

Tehát annak a valószínűsége, hogy  $x \leq a$  egyenlő  $u \leq u_a = (a - \mu)/\sigma$ . Lásd 6. ábra b., része!



6. ábra.

1., példa

Mi annak a valószínűsége, hogy  $x$  normális eloszlású valószínűségi változó ebbe az intervallumba esik:  $(\mu - \sigma, \mu + \sigma)$ ?

$$P(\mu - \sigma < x \leq \mu + \sigma) = F(\mu + \sigma) - F(\mu - \sigma) \quad (29)$$

Ezt a 7. ábra szemlélteti. Ekkor igaz, hogy

$$u_{felso} = \frac{\mu + \sigma - \mu}{\sigma} = 1 \quad (30)$$



és

$$u_{also} = \frac{\mu - \sigma - \mu}{\sigma} = -1 \quad (31)$$

A táblázatból látjuk, hogy  $F(1) = 0,84134$ . Mivel  $f(x)$  szimmetrikus függvény  $F(\infty) = 1$  és  $F(-a) = 1 - F(a)$ . Így  $F(-1) = 1 - F(1) = 0,15866$ , ezzel

$$P(\mu - \sigma < x \leq \mu + \sigma) = 0,68268 \quad (32)$$

Vagyis a valószínűség 68%. Hasonló számítással adódik:



7. ábra.



Intervallum	$\pm\sigma$	$\pm 2\sigma$	$\pm 3\sigma$
P	0,68268	0,9545	0,9973

1. táblázat.



2., példa

Egy  $x$  jelű,  $N(\mu, \sigma^2)$  normális eloszlású valószínűségi változó értékei milyen szimmetrikus intervallumban vannak 95%-os, illetve 99%-os valószínűséggel?  $u$  alsó és felső értékének segítségével! Tudjuk, hogy  $\alpha$  jelenti, hogy ezen kívül van, azaz jobb- és baloldalt  $\alpha/2$  ennek a valószínűsége, lásd 8. ábra!



8. ábra.

A táblázatból látjuk:

$\alpha$	0,05	0,01
$1 - \alpha$	0,95	0,99
$1 - \alpha/2$	0,975	0,995
$u$	1,96	2,58

2. táblázat.

Visszatérve az eredeti  $x$  változóra:

$$x_{also} = \mu - \sigma u_{\alpha/2}; \quad x_{felso} = \mu + \sigma u_{\alpha/2} \quad (33)$$

$\alpha$	0,05	0,01
$x_{also}$	$\mu - 1,96\sigma$	$\mu - 2,58\sigma$
$x_{felso}$	$\mu + 1,96\sigma$	$\mu + 2,58\sigma$

3. táblázat.

3., példa

Analitikai mérlegen tömegmérés esete. Tudjuk, a tömeg  $\mu = 5,00000 \text{ g}$ , a variancia négyzetgyöke  $\sigma = 10^{-4} \text{ g}$  és a mérés normális eloszlású.

a., Egy mérés eredménye 99%-os biztonsággal (valószínűséggel) milyen szimmetrikus intervallumba esik?

$$P[-u_{\alpha/2} < u \leq u_{\alpha/2}] = 1 - \alpha = 0,99 \quad (34)$$

$$u = \frac{x - \mu}{\sigma} = \frac{x - 5,00000}{10^{-4}} \quad (35)$$

$$P[\mu - u_{\alpha/2}\sigma < x \leq \mu + u_{\alpha/2}\sigma] = 0,99 \quad (36)$$

A táblázatból látjuk, hogy  $\alpha = 0,01$ -hez  $u_{\alpha/2} = 2,58$  tartozik, ezzel

$$P(5,00000 - 2,58 \cdot 10^{-4} < x \leq 5,00000 + 2,58 \cdot 10^{-4}) = 0,99 \quad (37)$$

A mérés eredménye 99%-os valószínűséggel a (4,99974; 5,00026) tartományba esik, a 4. jegy már bizonytalan!

b., Több mérési eredmény átlagának hibája mekkora intervallumba esik 99%-os biztonsággal?

$$P[-u_{\alpha/2} < u \leq u_{\alpha/2}] = 1 - \alpha = 0,99 \quad (38)$$

Itt

$$u = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}} \quad (39)$$

a hiba pedig  $(\bar{x} - \mu)$ .

$$P[-u_{\alpha/2} \sigma/\sqrt{n} < \bar{x} - \mu \leq u_{\alpha/2} \sigma/\sqrt{n}] = 0,99 \quad (40)$$

$$P[-2,58 \cdot 10^{-4}/\sqrt{n} < \bar{x} - \mu \leq 2,58 \cdot 10^{-4}/\sqrt{n}] = 0,99 \quad (41)$$

n	hibaintervallum fele	csökkenés mértéke
2	$1,82 \cdot 10^{-4}$	0,707
3	$1,49 \cdot 10^{-4}$	0,578
4	$1,29 \cdot 10^{-4}$	0,500
5	$1,15 \cdot 10^{-4}$	0,446
6	$1,05 \cdot 10^{-4}$	0,408
7	$0,97 \cdot 10^{-4}$	0,378

4. táblázat.

Látható, hogy 4 méréssel a hiba a felére, 7 méréssel majdnem a harmadára csökkenthető!

c., Hány mérés után csökken a középérték hibája 95%-os biztonsággal  $\pm 10^{-4}$  alá?

$$P[-u_{\alpha/2} < u \leq u_{\alpha/2}] = 1 - \alpha \quad (42)$$

$$u = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}} \quad (43)$$

$$P[-u_{\alpha/2} \sigma/\sqrt{n} < \bar{x} - \mu \leq u_{\alpha/2} \sigma/\sqrt{n}] = 1 - \alpha \quad (44)$$

Tehát a követelmény:  $|\bar{x} - \mu| < 10^{-4}$ , azaz  $u \sigma/\sqrt{n} < 10^{-4}$ . Mivel

$$\sigma = 10^{-4}; \quad \frac{u_{\alpha/2}}{\sqrt{n}} < 1; \quad n > [u_{\alpha/2}]^2 \quad (45)$$

A táblázatból  $u_{\alpha/2} = 1,96$ , ezért  $n > 1,96^2 = 3,86$  vagyis  $n=4$  elég.

*Centrális határeloszlási tétel:* bármilyen eloszlású sokaságból vett minták számtani középértékei - elég nagy minta esetén (min. 30-50) - közelítőleg normális eloszlást követnek az eredeti eloszlás várható értéke körül. Ezért van sok normális eloszlású változó!

A  $\chi^2$  eloszlás:

Vegyünk egy  $N(\mu, \sigma^2)$  normális eloszlású sokaságból  $\nu$  elemű mintát:  $x_1, x_2, \dots, x_i, x_\nu$ . Ezekből


$$u_i = \frac{x_i - \mu}{\sigma} \quad (46)$$

normalizált normális eloszlású  $[N(0,1)]$  valószínűségi változók képezhetők. A  $\chi^2$  eloszlású valószínűségi változót így kapjuk:

$$\chi^2 = u_1^2 + u_2^2 + \dots + u_i^2 + \dots + u_\nu^2 = \sum_{i=1}^{\nu} u_i^2 \quad (47)$$

A négyzetösszeg szabadságfok-számán a lineáris rendszer szabadságfok-számát értjük. A lineáris rendszer szabadsági fokát megkapjuk, ha a változók számából levonjuk a köztük lévő lineáris összefüggések számát. Mivel itt a tagok egymástól függetlenek, az összeadandók száma ( $\nu$ ) megegyezik a szabadsági fokok számával.

Az eloszlás sűrűségfüggvénye csak a  $\nu$  paramétert tartalmazza:  $f_\nu(\chi^2)$



9. ábra.

Várható értéke és varianciája:

$$M[\chi^2] = \nu; \quad Var[\chi^2] = 2\nu \quad (48)$$

A *t*-eloszlás (*Student*-eloszlás)

$u$  és  $\chi^2$  egymástól független valószínűségi változó. Az első  $N(0,1)$  eloszlású, a második  $\chi^2$  eloszlású  $\nu$  szabadsági fokkal. Legyen  $t$  egy új valószínűségi változó:

$$t = \frac{u}{\sqrt{\frac{\chi^2}{\nu}}} \quad (49)$$

Ehhez az úgynevezett Student-eloszlás tartozik. Ennek egyetlen paramétere  $\nu$ , a szabadsági fok. Ha  $\nu \rightarrow \infty$  a *t*-eloszlás tart a normális eloszláshoz. A gyakorlatban  $\nu > 30$  esetben ez igaz...


A középértékre vonatkozó

$$t = \frac{\bar{x} - \mu}{s/\sqrt{n}} \quad (50)$$


is *t*-eloszlású  $n-1$  szabadsági fokkal, ahol  $s$  a szórás. A *t*-eloszlás szimmetrikus:

$$F[t_{\alpha/2}] = 1 - F[t_{1-\alpha/2}] \quad (51)$$

Nem túl elegáns jelöléssel:  $t_{1-\alpha/2}$  helyett  $-t_{\alpha/2}$



10. ábra.



11. ábra.