

Mi az adat?

- **Az adat elemi ismeret.**
- Tények, fogalmak olyan megjelenési formája, amely alkalmas emberi eszközökkel történő értelmezésre, feldolgozásra, továbbításra.
- **Az adatokból** gondolkodás vagy gépi feldolgozás útján **információkat**, azaz új ismereteket nyerünk.
- **A számítástechnikai eszközökkel rögzített, azokkal feldolgozható és megjeleníthető információt** adatnak nevezzük.
- **Az információ tehát értelmezett adat.**

Adat osztályozása

- Az adatok **jellegük szerint** lehetnek:
- minőségi / megállapítható / kvalitatív,
- mennyiségi / mérhető / kvantitatív adatok.

- Az adatok **értékük / értékészletük** szerint lehetnek:
 - bináris,
 - diszkrét,
 - folytonos adatok.

Az adat típusa (skálája)

- **Nominális adat**: amelynek lehetséges értékei között csak az azonos vagy nem azonos reláció van értelmezve ($=$, \neq).
- **Ordinális adat**: amelynek lehetséges értékei között a kisebb v. nagyobb ($<$, $>$) reláció is megengedett az előőbi relációk mellett.
- **Intervallum adat**: amelynél fentiekén kívül az $+$, $-$, $*$ műveleteket is tudjuk értelmezni.
- **Arány skála adat**: mind a négy alapművelet értelmezve van ($/$).

Kategórikus adatok

Adatfajta	Az adatokon értelmezett relációk	Példa
Nominális (nevesítő)	=, ≠	Nem, faj, betegségfajta
Ordinális (rendező)	=, ≠, <, >	Betegség súlyossága, dohányzás súlyossága

Azokat a kategorikus adatokat, amelyek csak két osztály valamelyikébe sorolhatók, *dichotómikus* vagy *bináris* adatoknak nevezzük.

Metrikus (folytonos) adatok

Adatfajta	Az adatokon értelmezett relációk	Példa	Fontos
Intervallum	$=, \neq, <, >, +, -, *$	Potenciál, Celsius fokban mért hőmérséklet	Nincs fix 0 pont, az önkényes.
Arány	$=, \neq, <, >, +, -, *, \div$	Tömeg, Abszolút hőmérséklet, vérnyomás	Létezik fix 0 pont.

A kvantitatív adatok lehetnek folytonos vagy diszkrét (mérhető vagy leszámítható, gyakran metrikusnak nevezettek) adatok.

Sokaság (n, populáció)

- Mindazon elemek halmaza (a vizsgálat tárgya), amelyre statisztikai következtetés irányul.
- A sokaság nem emberek (egyedek), hanem egy őket jellemző ismérv (változó) által felvett vagy felvehető értékek halmaza.
- Két típusa van: időpontban (**álló sokaság**) vagy időintervallumban (**mozgó sokaság**) vizsgáljuk-e.

Minta (N)

- Egy adott véges számú sokaságból kiválasztott – véges számú – egységek összessége.
- A minta elemszáma mindig kisebb, mint maga az alapsokaság.
- Ha e kettő megegyezik, akkor cenzusról beszélünk (például népszámlálás).
- Mintaelem: a minta egyes elemei.

Véletlen minta

- A minták egy speciális esete.
- A véletlen kiválasztás esetében az alapsokaság minden egységéről megmondható, hogy milyen valószínűséggel kerülhet be a mintába.
- A társadalomkutatás módszertana, azaz a matematikai statisztika a véletlen mintavételre támaszkodik.

Reprezentativitás

- Egy minta bizonyos változók mentén akkor reprezentatív, ha a mintába került elemek (emberek) ugyan olyan arányban vannak jelen, mint az alapsokaságban.
- Tehát egy minta csak bizonyos szempontok alapján nevezhető reprezentatívnak.
- Ha más szempontokat veszünk figyelembe, akkor mintánk lehet, hogy nem reprezentatív.

Mintavételi hiba

- A mintavétel hibája abból adódik, hogy nem a teljes populációt kérdezzük meg, hanem annak csak egy részét.
- Így információink részlegesek lesznek a teljes alapsokaságról.
- A mintavételi hiba mértéke szoros összefüggésben van a minta elemszámával, valamint a mintavételi módszerrel.
- A mintavételi hiba mértéke akkor számolható ki érvényesen, ha véletlen mintát vettünk.


Nem mintavételi hiba

- A nem mintavételi hibák az adatfelvételhez kapcsolódnak, nincsenek kapcsolatban sem a mintavétel módszerével, sem a minta elemszámával. Nem mintavételi hibák összetevői az alábbiak lehetnek:
 - a kérdőív hibás megszerkesztése;
 - kérdezőbiztosok munkájának hibái;
 - hibás rögzítés;
 - a mintába bekerült válaszadó félreérthető vagy valós véleményét elfedő válasza, stb.

Mit kell tenni?

A klinikai tervezés előtt:

- ◆ Mintaszám meghatározás
- ◆ Erő (Power) analízis



$n=2987?!$

Valószínűség

- Azt a számot, amely körül egy esemény relatív gyakorisága ingadozik, az illető esemény valószínűségének nevezzük.
- Egy esemény bekövetkezésének vagy be nem következésének mértékbeli megadása.
- A valószínűség, mint mérték 0 és 1 közötti szám.
- A jelölés a latin probabilitas, valószínűség szó kezdőbetűjéből ered.

- **Eseménynek** nevezünk mindent, amiről a kísérlet elvégzése után eldönthető, hogy bekövetkezett-e, vagy sem (**elemi esemény**).
- Valamely kísérlet összes kimenetele egy halmazt alkot. Ezt nevezzük **eseménytérnek** (Ω).
- **Biztos eseményről** akkor beszélünk, ha a kísérlet során biztosan (minden kimenetelnél) bekövetkezik.
- Azt az eseményt, mely akkor és csak akkor következik be, ha az A esemény nem következik be, az A esemény **ellentett eseményének** nevezzük (\bar{A}) .

Alapfogalmak

1. Valószínűség:

Eseményeken értelmezett számértékű függvény (mérték).
Jelölésben $P(A)=p$

Kolmogorov axiómák:

- $0 \leq P(A) \leq 1$
- $P(\emptyset)=0$ és $P(I)=1$
- Ha $A \cap B = \emptyset \Rightarrow P(A+B) = P(A) + P(B)$

2. Valószínűségszámítás és a statisztika kapcsolata (klasszikus modell)

$$p = \frac{k}{n} = \frac{\text{kedvező esetek száma}}{\text{összes eset száma}}$$

3. Statisztikai próba (teszt):

A mért adatokon értelmezett függvény.

4. Szignifikancia értelmezése : $p < 0.05$

Feltételes valószínűség

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

Teljes valószínűség tétele

Ha $B_1, B_2, B_3, \dots, B_n$ események teljes eseményrendszert alkotnak és $P(B_i) \neq 0$, akkor az A esemény valószínűsége

$$P(A) = \sum_{i=1}^N P(A | B_i) \cdot P(B_i)$$

Bayes elmélet

Ha a $B_1, B_2, B_3, \dots, B_n$ események teljes eseményrendszert alkotnak és $P(B_i) \neq 0$, akkor tetszőleges A esemény mellett ($P(A) \neq 0$), igaz

$$P(B_i | A) = \frac{P(A | B_i) \cdot P(B_i)}{\sum_{k=1}^N P(A | B_k) \cdot P(B_k)}$$

Mennyi a valószínűsége, hogy érmével fejet dobunk?

Egy dobásnak 2 kimenetel van, tehát $n = 2$.

Kedvező számunkra, hogy fejre esik az érme, tehát

$$k = 1$$

$$P(\text{fejet dobunk}) = \frac{1}{2} = 0,5 = 50\%$$

Mennyi a valószínűsége, kockával páros számot dobunk?

Egy dobásnak 6 kimenetele van, $n = 6$.

Kedvező számunkra 3 eset, így $k = 3$

$$P(\text{páros számot dobunk kockával}) = \frac{3}{6} = \frac{1}{2} = 0.5 = 50\%$$

Mennyi a valószínűsége, hogy kockával nem 6-ost dobunk?

$$n = 6$$

$$k = 5$$

$$P(\text{nem 6-ost dobunk}) = \frac{5}{6} = 0,833$$

Egy dobozban 5 piros golyó van. Hány fehér golyót tegyünk hozzá, hogy a fehér golyó húzásának valószínűsége 80% legyen?

Jelöljük x -szel a fehér golyók számát!

$$n = 5 + x$$

$$k = x$$

$$P = 0,8$$



$$\frac{x}{5 + x} = 0,8$$

$$x = 0,8(5 + x)$$

$$x = 4 + 0,8x$$

$$0,2x = 4$$

$$x = 20$$

Tehát 20 fehér golyót kell a dobozba tenni. Ekkor az össze golyók száma 25 (ez az n), ebből 20 fehér (ez a k), így a fehér golyó húzásának valószínűsége

$$\frac{20}{25} = \frac{4}{5} = \frac{8}{10} = 0,8$$

Mennyi a valószínűsége, hogy ötösöd lesz a lottón?

$$n = \frac{90 \cdot 89 \cdot 88 \cdot 87 \cdot 86}{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1} = 43.949.268$$

$$k = 1$$

P = házi feladat 😊

Változó

- Több értéket képes fölvenni, így nem kell egyenként behelyettesítenünk őket például egy függvénybe, hanem elegendő csak a változó.
- A változónk értékét külön tárolhatjuk, vagy más módon is megadhatjuk – például intervallummal.
- Természetesen nem csak olyan változók léteznek, melyek számokat vehetnek fel.

Valószínűségi változó

- A valószínűségi változó a változók speciális esete.
- Ebben az esetben meg lehet mondani, hogy a változó milyen valószínűséggel veheti fel értékeit, tehát minden egyes általa fölvehető értékhez hozzá tudunk rendelni egy valószínűséget.

- A statisztikában gyakran előfordul még a **függő és független változók** megkülönböztetése. A gyakorlatban ez azt jelenti, hogy egyik tulajdonság függvényében miként változik egy másik tulajdonság, ami értelemszerűen többváltozós esetekre is értelmezhető.

- **Gyakoriság:** egy vagy több változó által felvehető értékre, értékekre jutó megfigyelések száma.
- **Relatív gyakoriság:** ha egy változó által felvehető értékekre jutó megfigyelések számát elosztjuk a teljes mintanagysággal, akkor a relatív gyakorisághoz jutunk.

Eloszlás

- A statisztika központi fogalma: valami vagy valamik hol vannak, hogyan oszlanak el, hogyan helyezkednek el.
- A sokaság eloszlását – a változó típusától függően – jellemezhetjük:
 - függvénnel (valószínűségi sűrűségfüggvény, kumulatív eloszlásfüggvény),
 - vagy paraméteresen (elméleti szórás, várható érték stb.).

Valószínűségeloszlás

- Egy teljes eseményrendszer valószínűségeinek sorozatát valószínűségeloszlásnak, vagy röviden eloszlásnak nevezzük.
- Olyan függvény, mely leírja, hogy egy valószínűségi változó milyen valószínűséggel vehet fel egy bizonyos értéket.
- Eloszlásfüggvénye minden valószínűségi változónak létezik.

Diszkrét eloszlások

Csak diszkrét, definiált értékeket vehet fel.

Néhány véges tartományú diszkrét eloszlás:

Binomiális eloszlás

Poisson-féle binomiális eloszlás

Bernoulli-eloszlás

Diszkrét egyenletes eloszlás

Hipergeometrikus eloszlás

Folytonos eloszlások

A folytonos eloszlású valószínűségi változó végtelen sok értéket vehet fel.

1. Néhány zárt intervallumú folytonos eloszlás:

- Arkuszszinusz-eloszlás
- Logit normális eloszlás

2. Félig végtelen intervallumú folytonos eloszlás $[0, \infty)$:

- Khí-eloszlás
- Khí-négyzet eloszlás
- Exponenciális eloszlás
- F-eloszlás

3. A teljes valós tartományra érvényes eloszlások $[-\infty, \infty)$

- Normális eloszlás
- T-eloszlás

Valószínűségi változók

```
graph TD; A[Valószínűségi változók] --> B[Diszkrét]; A --> C[Folytonos]; B --- D["p_k = P(A_k) = P(ξ < x)"]; E[Eloszlás függvény] --> F["F(x) = P(ξ < x)"]; E --> G["F(x)' = f(x)"];
```

Diszkrét

$$p_k = P(A_k) = P(\xi < x)$$

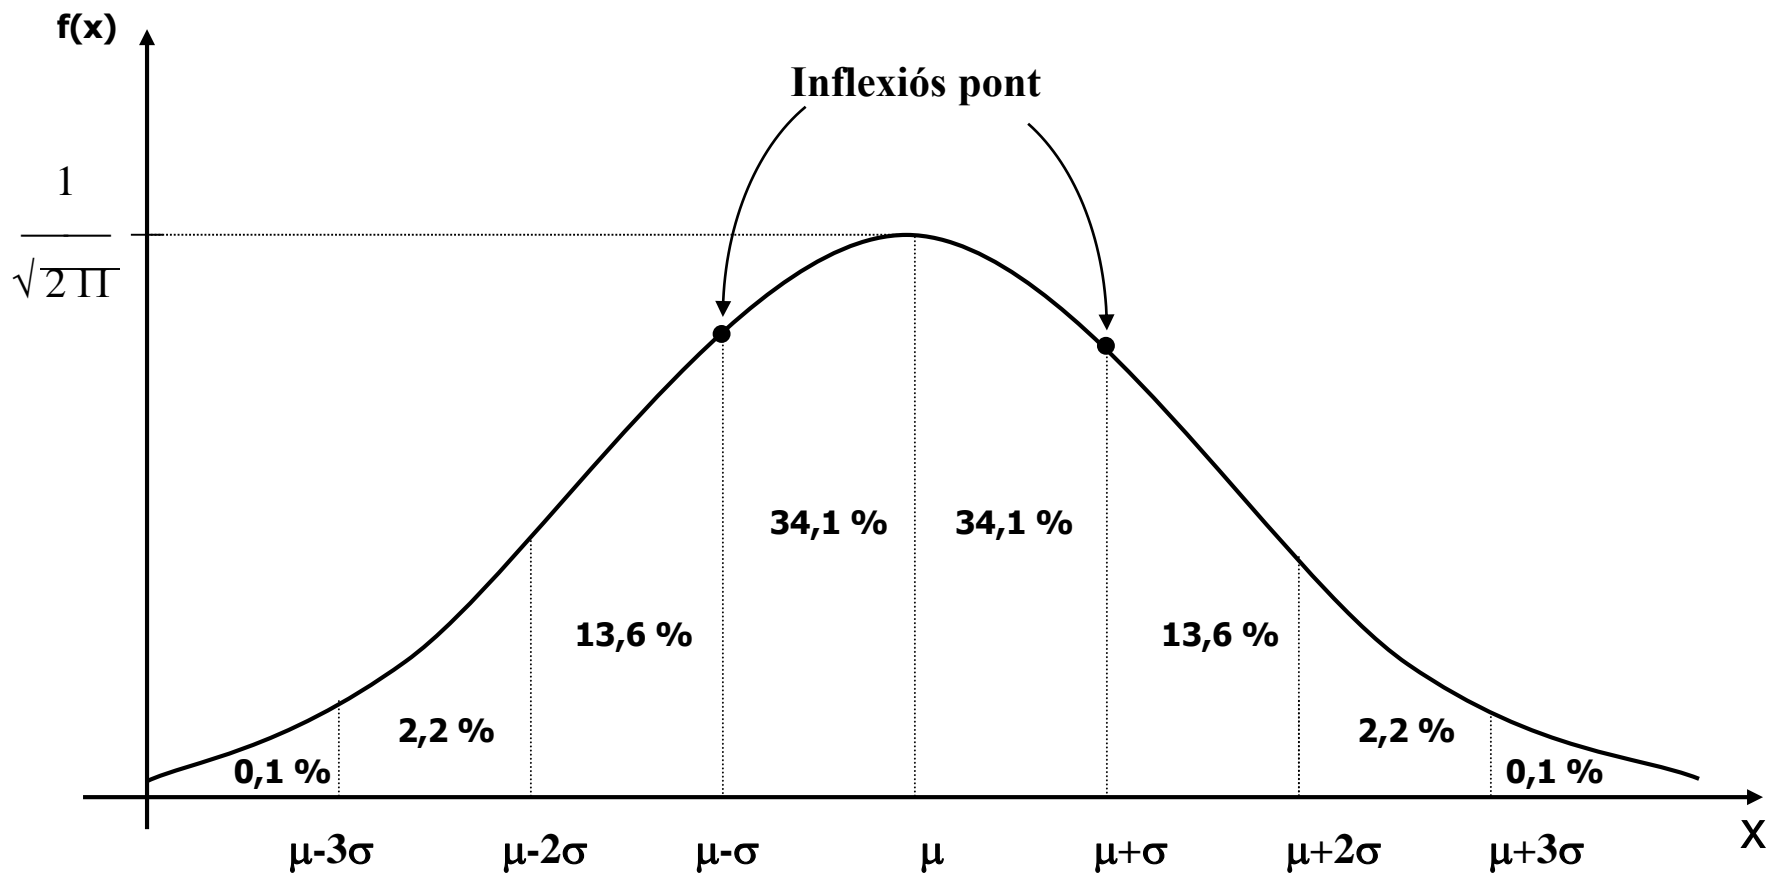
Folytonos

Eloszlás függvény

$$F(x) = P(\xi < x)$$

$$F(x)' = f(x)$$

Legfontosabb folytonos eloszlások




Normális eloszlás tulajdonságai

Sűrűségfüggvény

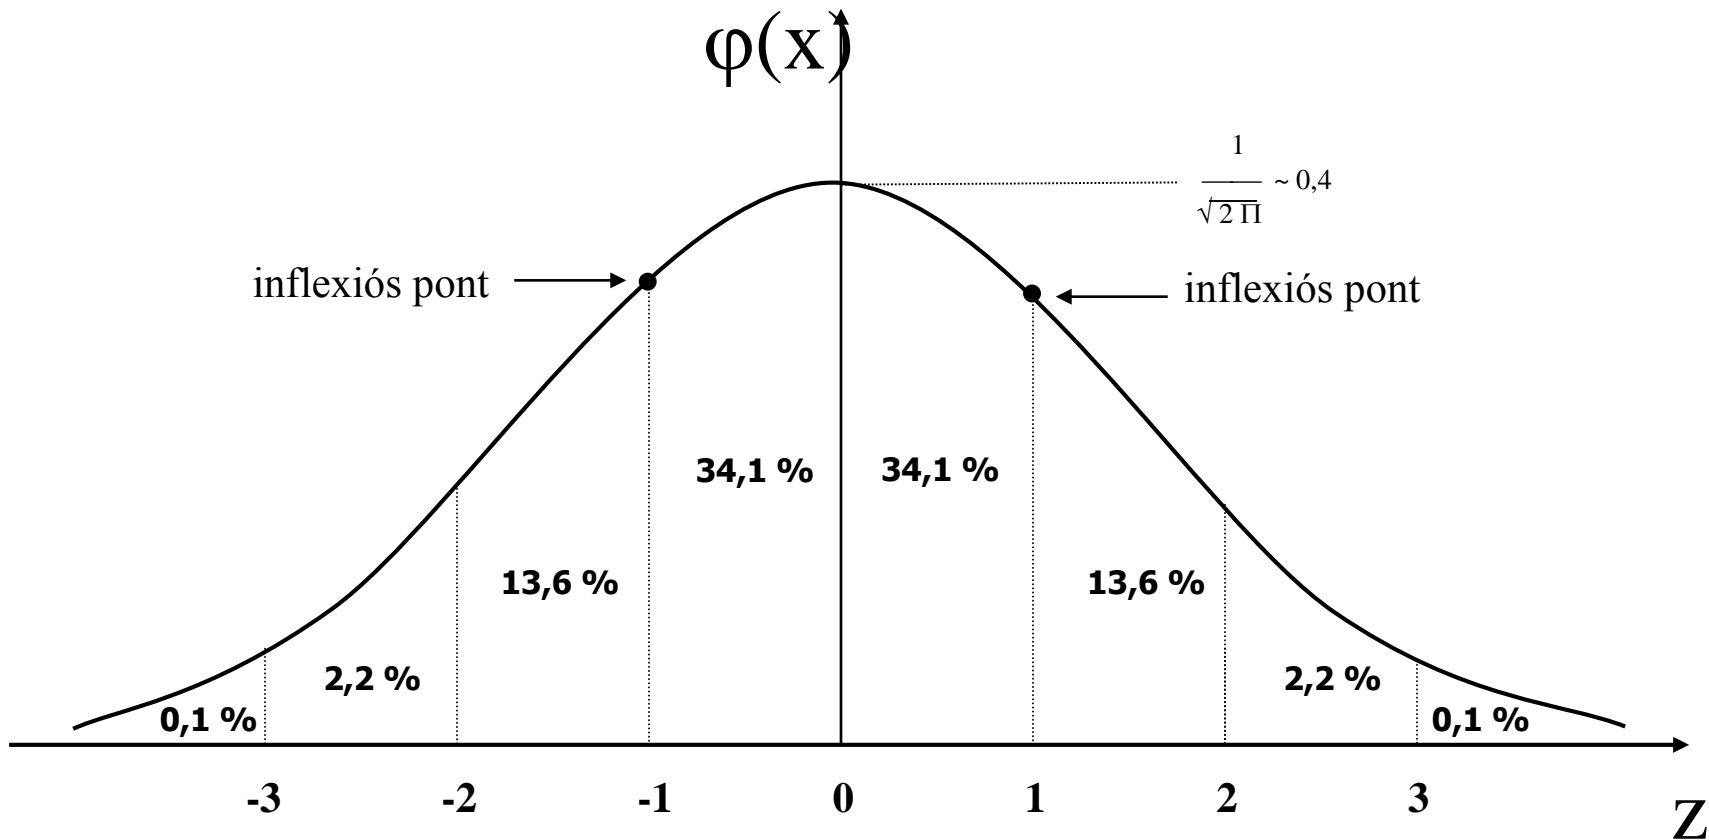
$$f(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Normáeloszlás eloszlásfüggvénye



Eloszlásfüggvény

$$F(x) = \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx$$




Standard normális eloszlás

$$Z = \frac{x - \mu}{\sigma}$$

Standard normális eloszlás sűrűségfüggvénye

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

Standard normáeloszlás eloszlásfüggvénye



Standard normális eloszlás eloszlásfüggvénye

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


A normál eloszlás nevezetes értékei

$\alpha\%$	$\mu \pm \sigma$
5	1,96
1	2,58
0,1	3,29


Az eloszlás alakjának jellemzése

- Ferdeség (skewness, normális eloszlás=0 körüli érték)
- Csúcsosság (kurtosis, normális eloszlás=0 körüli érték)


POSITIVELY SKEWED



NEGATIVELY SKEWED



BI-MODAL



További folytonos eloszlások

- t-eloszlás
- Exponenciális eloszlás
- Egyenletes eloszlás
- F-eloszlás
- Gamma