

# Biofizika I.

## fogorvostan hallgatóknak

2. előadás:

Biostatisztika II.

2019. Szeptember 16.

Veres Dániel

# Ismétlés: Alapsokaság és minta

## (Következtető statisztika alap problémája)

Alapsokaság (populáció)



Az **alapsokaság** rendszerint olyan méretű, hogy az összes eleme nem vizsgálható meg.

**BIZONYTALANSÁG!**  
(P és H)

A minta jellemzői alapján az alapsokaságra vonatkozó következtetést vonhatunk le

Minta



Emiatt az alapsokaságnak csak egy részhalmazát vizsgáljuk, ezt nevezzük mintának.

A minta elemein méréseket végzünk, majd az így keletkező adathalmazt (amit szintén mintának nevezünk) grafikusán és matematikailag jellemezzük

„VÉLETLEN”

# Becslés

Alapsokaság (populáció)

Valódi érték

Valószínűség

Várható érték (populációs átlag)

Elméleti variancia (szórásnégyzet)

Két várható érték különbsége



Becslés

Minta

Becslés

Relatív gyakoriság

Minta átlaga

Minta variancia

Mintaátlagok különbsége

# Becslés

Alapsokaság (populáció)

Valódi érték

Valószínűség

Várható érték (populációs átlag)

Elméleti variancia (szórásnégyzet)

...



Becslés

Minta

Becslés

Relatív gyakoriság

Minta átlaga

Minta mediánja?

Minta variancia - melyik?

$$v1 = \frac{\sum_{i=1}^n (\bar{x} - x_i)^2}{n}$$

$$v1 = \frac{\sum_{i=1}^n (\bar{x} - x_i)^2}{n-1}$$

# Hiba

Alapsokaság (populáció)

- Valódi érték




Becslés

Minta

- Becslések





/ Hiba



Több véletlen mintavételt  
képzelünk el –becslések

# Hiba – 2 dimenziója

„Átlagos eltérés” (torzítás)  
Szisztematikus hiba







1. A becslések változékonysága

2. A becslések „közepének”  
eltérése a valódi értéktől

„Változékonyság” (szóródás);  
Véletlen hiba (mintavételi hiba)

# Hiba – 2 dimenziója

„Átlagos eltérés” (torzítás)  
Szisztematikus hiba



„Változékonyság” (szóródás);  
Véletlen hiba

Jó becslés, ha:

*Torzítatlan:*

A becslések „közepe” (várható értéke) a valódi érték

*Hatásos:*

A becslések változékonysága a lehető legkisebb

*Konzisztens:*

az elemszám növelésével csökken a becslés változékonysága  
( )

# Néhány megjegyzés

- A várható érték becslésére az átlag torzítatlan, konzisztens és a leghatásosabb
- A szórás becslésénél az  $n-1$ -gyel való osztás torzítatlan, de  $n$ -nel osztva torzított



# Konfidencia intervallumok

De nekünk csak 1 mintánk van, valódi értéket nem ismerjük!

– Akkor számítható egyáltalán a hiba?

IGEN, a véletlen hiba (mintavételi hiba): ez a becslés standard hibája - a mintából becsülhető!

# Konfidencia intervallumok

De nekünk csak 1 mintánk van, valódi értéket nem ismerjük!

– Akkor számítható egyáltalán a hiba?

IGEN, a véletlen hiba (mintavételi hiba): ez a becslés standard hibája - a mintából becsülhető!

Példa:

az átlag standard hibája (röviden standard hiba, vagy átlag hibája, SEM)

***Emlékeztető: Centrális határeloszlás tétele (mintavételi átlagokra):***

ha egy adathalmazból  $n$  elemű mintákat veszünk, akkor elég általános feltételek teljesülése esetén a minták átlagai normál eloszlásúak lesznek, és az eloszlás varianciája az eredeti eloszlás varianciájának  $n$ -ed része lesz.

# Konfidencia intervallumok

1. Tehát az átlag standard hibája (szóródásának mértéke): a minta varianciájának  $n$ -ed részének négyzetgyöke.
2. Megadható egy olyan tartomány, amely az átlagot adott valószínűséggel tartalmazza: ez az átlag konfidencia intervalluma.  
az adott valószínűség: konfidenciaszint

Az átlag esetében (a normál eloszlás miatt) pl:

Az átlag 95% szintű konfidencia intervallumának határai:

$$\sim \bar{x} \pm 2 * SEM$$

Más becslésre is megadható adott szintű konfidencia intervallum!

Mutatja a becslés értékét, annak hibáját, adott valószínűségű intervallumát

# Hipotézisvizsgálatok

## Mintavételi (véletlen hiba) másképp

Hipotézisvizsgálat **célja**: eldöntendő kérdésre statisztikai választ adjon

### Hogyan?

Állítás *direkt bizonyítása*: minden lehetséges esetre belátom, hogy igaz.

pl: 1,2...n számok összege:  $(n+1)*(n/2)$  – teljes indukcióval

Állítás *indirekt bizonyítás*: felteszem a pontos ellenkezőjét és belátom, hogy nem igaz.

# Indirekt bizonyítás

Egy dobozban van 100 üveggolyónk. Mindegyikük vagy piros, vagy fehér.

**1. eset: A feltevésünk ( $H$ ):** mind fehér.

**Kísérlet:** véletlenül kiveszünk egy golyót a dobozból.

**Megfigyelés:** az első kivett golyó piros színű.

**Következtetés:** a megfigyelésünk valószínűsége, *ha a  $H$  igaz*, 0: a feltevésünk 100% biztonsággal téves.

**2. eset: A feltevésünk ( $H$ ):** 99 fehér és egy piros.

**Kísérlet:** véletlenül kiveszünk és visszarakunk egy golyót, ezt 5-ször végezzük el.

**Megfigyelés:** mind az 5 piros.

**Következtetés:** a  $H$  *majdnem* 100% biztonsággal téves: a megfigyelésünk valószínűsége, *ha a  $H$  igaz*,  $0.01^5 = 10^{-10}$ : (gyakorlatilag lehetetlen).

**3. eset: A feltevésünk ( $H$ ):** 50 fehér és 50 piros.

**Kísérlet:** véletlenül kiveszünk és visszarakunk egy golyót, ezt 5-ször végezzük el.

**Megfigyelés:** mind az 5 piros.

**Következtetés:** most nem olyan egyértelmű: a megfigyelésünk valószínűsége, *ha a  $H$  igaz*,  $0.5^5 = 0.03125$ : alacsony de azért nem túl valószínűtlen..

**4. eset: A feltevésünk ( $H$ ):** mind piros.

**Kísérlet:** véletlenül kiveszünk és visszarakunk egy golyót, ezt 5-ször végezzük el.

**Megfigyelés:** mind az 5 piros.

**Következtetés:** a megfigyelésünk valószínűsége, *ha a  $H$  igaz*,  $1^5 = 1$ . Ez mit is jelent?

# Indirekt bizonyítás


Egy dobozban van 100 üveggolyónk. Mindegyikük vagy piros, vagy fehér.

**1. eset: A feltevésünk ( $H$ ):** mind fehér.

**Kísérlet:** véletlenül kiveszünk egy golyót a dobozból.

**Megfigyelés:** az első kivett golyó piros színű.

**Következtetés:** a megfigyelésünk valószínűsége, ha a  $H$  igaz, a feltevésünk 100% biztonsággal téves.



**A falszifikáció működik**

**A verifikáció nem működik**

**4. eset: A feltevésünk ( $H$ ):** mind piros.

**Kísérlet:** véletlenül kiveszünk és visszarakunk egy golyót, ezt 5-ször végezzük el.

**Megfigyelés:** az első kivett golyó piros színű.

**Következtetés:** a megfigyelésünk valószínűsége, ha a  $H$  igaz,  $1^5 = 1$ . Ez mit is jelent?

A feltevés igaz

Biztos esemény

# Indirekt bizonyítás

**A 2. és 3. eset?**

**Matematikai logika:**

Van egy feltevésünk ( $H$ ).

Ha  $H$  igaz, az  $E$  esemény nem következhet be.

$E$  bekövetkezik.

Tehát  $H$  hamis.

Amint azt az előzőekben láttuk, **egy feltevést csak elvetni tudunk.**

**Statisztikai logika:**

Van egy feltevésünk ( $H$ ).

Ha  $H$  igaz, az  $E$  esemény bekövetkezése nagyon valószínűtlen.

$E$  bekövetkezik.

Elvetjük  $H$ -t. De sohasem lehetünk 100%-ig bizonyosak, hogy  $H$  hamis.

Ez esetben **egy feltevést még elvetni sem tudunk százszázalékos bizonyossággal**  
– **mintavételi hiba lehetséges. ENNEK VALÓSZÍNŰSÉGÉT KELLENE MEGBECSÜLNI**

# Milyen legyen a kérdés?

...legyen eldöntendő (igen/nem, dichotomikus).

- |   |  |
|---|--|
| - 50%-e a mielómások ötéves túlélési aránya (vagyis valsége)?                                 | - Mekkora a mielómások ötéves túlélési aránya?                 |
| - Eltér-e a Cushing-kórosok vérkoleszterinszintje a normálisnak tartott 200 mg/dL értéktől? ✓ | - Mi a Cushing-kórosok koleszterinszintjének várható értéke? X |

...esetek halmazára és ne egyedi esetre vonatkozzon.

(És a kérdés mindig az alapsokaságra irányul, nem a mintára.)

- |  |   |
|--|---|
| - 50%-e a mielómások ötéves túlélési aránya? ✓ | - Élni fog-e még ez a mielóma beteg 5 év múlva? X |
|--|---|

...legalább az egyik válaszlehetőségnek egyértelműnek kell lennie.

- |  |  |
|--|--|
| - 50%-e a mielómások ötéves túlélési aránya? ✓ | - Kevesebb-e a mielómások túlélési aránya, mint 50%? X |
|--|--|



# Milyen legyen a hipotézis?

Két válaszunk (feltevésünk) van a kérdésre:

## A nullhipotézis ( $H_0$ )

- **Egyértelmű:** csak egyféleképpen teljesülhet. Valamilyen formában szerepel benne az = jel.

A mielóma öt éves túlélési aránya 50%.

- A tudomány **jelenleg elfogadott álláspontját** tükrözi,

A Cushing kórosok vérkoleszterinszintje megegyezik az egészségesek alapsokaságának átlagával.

vagy valamit, ami „közhelyes”, kevés benne a megkötés (Occam borotvája).

Az érmefeldobásban a fejek valsege 50%.

- **Nem** feltétlenül nemleges válasz a feltett kérdésre.

## Az alternatív vagy ellenhipotézis ( $H_1$ )

- Jellemzően **többféleképpen is teljesülhet.**

A mielóma öt éves túlélési aránya nem 50%.

(lehet kissé több vagy sokkal kevesebb stb.)

- A tudományos konszenzusnak ellent-mondó **új megállapítást** fogalmaz meg,

A Cushing kórosok vérkoleszterinszintje eltér az egészségesek alapsokaságának átlagától.

vagy egy kevésbé közhelyes, megkötéseket tartalmazó állítást.

Az érmefeldobásban a fejek valsege nem 50%.

- Legtöbbször a  **$H_0$ -sel komplementer** (vagyis annak tagadása).

$H_1 = \text{nem } H_0$

# Mintavételből származó („véletlen”) hiba

Hipotézisvizsgálat **célja: eldöntendő kérdésre statisztikai választ** adjon

Kiindulópont: az eldöntendő kérdés statisztikai átfogalmazása, majd :

$H_0$ : nullhipotézis – „véletlen” hiba

$H_a$  (vagy  $H_1$ ): alternatív hipotézis (ellenhipotézis) – nem  $H_0$

Döntés alapja: a „véletlen” szerepe a  $H_0$  esetén (mintavételi hiba)

A minta az, amely esetleg megcáfolja  $H_0$ -t

# Mintavételből származó („véletlen”) hiba

Hipotézisvizsgálat **célja**: eldöntendő kérdésre statisztikai választ adjon

Kiindulópont: az eldöntendő kérdés statisztikai átfogalmazása, majd :

$H_0$ : nullhipotézis – „véletlen” hiba

$H_a$  (vagy  $H_1$ ): alternatív hipotézis (ellenhipotézis) – nem  $H_0$

Döntés alapja: a „véletlen” szerepe a  $H_0$  esetén (mintavételi hiba)

A minta az, amely esetleg megcáfolja  $H_0$ -t

		A populációban (a valóságban) a null hipotézis:	
		Igaz	Hamis
A döntés: a null hipotézist:	Megtartom (Nem vetem el)	Helyes döntés	Hiba ( <b>másod fajú</b> ) ( $\beta$ ) (álnegatív eredmény)
	Elvetem	Hiba ( <b>első fajú</b> ) ( $\alpha$ ) (álpozitív eredmény)	Helyes döntés ( <b>erő</b> ) ( $1-\beta$ )

# Egyszerűsített példa 1. lépések

Szituáció: Dobókockás társasjátékot játszunk – nem mi nyerünk...  
„Rossz” a dobókocka?

Mi a kérdés??!! (és mire vonatkozik):

Minden oldala ugyanolyan valószínűségű-e? (ennek a kockának)  
A hatos dobás valószínűsége eltér  $1/6$ -tól, még hozzá nagyobb?  
– most válasszuk ezt

Nullhipotézis ??!!:

A 6-os dobás valószínűsége  $1/6$  vagy kisebb – (összetett hipotézis)

Vegyük az alternatív hipotézis szempontjából „legrosszabb esetet”

(hiszen ha akárcsak egy eleme az összetett hipotézisnek „megfelelhet” a nullhipotézisnek, akár nincs bizonyíték az elvetésre a teljes

tartományban):

$H_0$ : A 6-os dobás valószínűsége  $1/6$ .

$H_a$ : nagyobb  $1/6$

# Egyszerűsített példa további lépések

Mi a kérdés: A hatos dobás valószínűsége eltér  $1/6$ -tól, még hozzá nagyobb?

Nullhipotézis:  $H_0$ : A 6-os dobás valószínűsége  $1/6$ .

Mennyi bizonyíték kell, hogy eltérőnek tekintsem? - Szignifikancia szint ??!:

Hatóság megadta... Adott terület szakirodalma --- **KIINDULÓPONT**, de kisebb/nagyobb, gyakoribb/ritkább mellékhatások?, olcsóbb/ drágább?...  
itt: minden hétvégén játszunk vele, dobókockát nem drága lecserélni  
– legyen 5% helyett 10% (kevesebb bizonyíték elég  $H_0$  elvetéséhez)

Bizonyíték gyűjtése – a minta ??!! (hogyan, mennyi...kérdezze statisztikusát):

24 dobásból 6 darab 6-os.

Tényleg a kérdésre válaszolok?

Módosítanom/pontosítanom kell a kérdést? (mire vonatkozik)  
(pl. itt: dobókockányi lukak vannak az asztalon...)

# Egyszerűsített példa további lépések

Mi a kérdés: A hatos dobás valószínűsége eltér  $1/6$ -tól, még hozzá nagyobb?

Nullhipotézis:  $H_0$ : A 6-os dobás valószínűsége  $1/6$ .

Szignifikancia szint: 10%

A minta: 24 dobásból 6 darab 6-os.

Lényeges a különbség egyáltalán – releváns ??!:

24 dobásból 6 darab 6-ost dobtam, ez  $6/24 = 1/4$  ez **1,5-szeres** az  $1/6$ -nak  
– igen, ez nekem lényeges

Mennyi a bizonyíték – p-érték ??!:

Hogyan számoljak?, (torzítatlanul, hatásosan, konzisztensen...)

Lényeges: kérdés, változók mérési skálája, mérési körülmények

Számolás során kell:


*Nulleloszlás* – ha a null hipotézis igaz, mekkora a valószínűsége az elméletileg lehetséges mintáknak, amit így vettünk?

A minta „helye” ebben az eloszlásban:

*próbatatisztika* (teszt-statisztika, pl: valószínűség, t-érték, p-érték...)

# A számolás a „háttérben”

Binomiális  
próbával!



# Egyszerűsített példa további lépések

Mi a kérdés: A hatos dobás valószínűsége eltér  $1/6$ -tól, még hozzá nagyobb?

Nullhipotézis:  $H_0$ : A 6-os dobás valószínűsége  $1/6$ .

Szignifikancia szint: 10%

A minta: 24 dobásból 6 darab 6-os.

Lényeges a különbség egyáltalán – releváns: minta alapján:  $1/4$  ez **1,5**-szeres az  $1/6$ -nak

Mennyi a bizonyíték – p-érték: 0,1995

Döntés: nincs elég bizonyíték az elvetésre – megtartjuk a  $H_0$ -t

		A populációban (a valóságban) a null hipotézis:	
		Igaz	Hamis
A döntés: a null hipotézist:	Megtartom (Nem vetem el)	Helyes döntés	Hiba ( <b>másod fajú</b> ) ( $\beta$ ) (álnegatív eredmény)
	Elvetem	Hiba ( <b>első fajú</b> ) ( $\alpha$ ) (álpozitív eredmény)	Helyes döntés ( <b>erő</b> ) ( $1-\beta$ )



# Egymintás Student-féle t-próba

## Mire vagyok kíváncsi

A minta várható értéke megegyezik-e egy ismert populációátlaggal

## Változó típusa

1 számszerű és folytonos

## Feltételek

Egymástól független megfigyelések

átlagok eloszlása legyen normál azaz:

normál eloszlású változó vagy nagy minta (CLT miatt)

## Megjegyzés: Számolás:

$$t = \frac{\bar{x} - \mu}{s / \sqrt{n}}$$

normalitást NE teszteljük másik hipotézisvizsgálattal! Előzetes tudásunk, ábrázolás alapján

(+teszt növeli az elsőfajú hibát, „multiplicitás”)

# Párosított t-próba

Mire vagyok kíváncsi

Két várható érték megegyezik-e - párosított csoportokban

Változó típusa

1 számszerű és folytonos, valamint 1 bináris („csoportok”)

Feltételek

Egymástól független megfigyelések a csoportokban, párosított csoportok

átlagok különbségének eloszlása legyen normál azaz:

normál eloszlású különbség vagy nagy minta

Megjegyzés:

párosított próbák ereje általában nagyobb, mint nem párosítotté  
egyéb helyparaméterek (kvantilisek) összehasonlítására is jó  
átlagok különbsége = különbségek átlaga

# Student-féle 2 mintás t-próba

Mire vagyok kíváncsi

Két várható érték megegyezik-e

Változó típusa

1 számszerű és folytonos, valamint 1 bináris („csoportok”)

Feltételek

Csoportonként és egymástól is független megfigyelések  
átlagok eloszlása legyen normál mindkét csoportban azaz:

normál eloszlás a csoportokban vagy nagy minta  
szórások azonosak legyenek a csoportokban

Megjegyzés:

egyéb helyparaméterek (kvantilisek) összehasonlítására is jó  
szórásokat általában nem ismerjük, ne teszteljük! (multiplicitás)

Welch próbát használjunk!

# Welch-féle t-próba

Mire vagyok kíváncsi

Két várható megegyezik-e

Változó típusa

1 számszerű és folytonos, valamint 1 bináris („csoportok”)

Feltételek

Csoportonként és egymástól is független megfigyelések  
átlagok eloszlása legyen normál mindkét csoportban azaz:  
normál eloszlás a csoportokban vagy nagy minta

Megjegyzés:

egyéb helyparaméterek (kvantilisek) összehasonlítására is jó  
nem érzékeny az eltérő varianciákra (robosztus a varianciák  
eltérésére)

# Khi-négyzet függetlenség próba

## Mire vagyok kíváncsi

Ismeretlen eloszlás, illetve gyakoriságok és ismert eloszlás megegyezik-e

Másképp: a 2 változó független-e

## Változó típusa

2 kategoriális változó

## Feltételek

Egymástól független megfigyelések

Az összes „elvárt” gyakoriság nagyobb, mint 1 és maximum 20%-uk kisebb, mint 5.

# „Korrelációs” t-próba (Pearson lineáris regresszió)

Mire vagyok kíváncsi

2 változó (lineárisan) függ-e egymástól

Változó típusa

2 számszerű változó (X és Y)

Feltételek

Egymástól független megfigyelések (x és y párok)

Lineáris összefüggést feltételezünk

x értékei mérési hiba nélküliek

minden x értékre y-ok eloszlása normális

minden x értékre y-ok szórása azonos

Megjegyzés:

2 értéket becslünk: a lineáris meredekségét és tengelymetszetét  
a meredekség a lényeges, ezt teszteljük

# Releváns, de mégsem szignifikáns

## Okai lehetnek:

kicsi statisztikai erő:

kicsi elemszám (+klinikai problémák: pénz, etikai kérdések)

nagy a változatosság a vizsgált paraméterben, illetve alanyokban

kicsi erejű próbát használunk

(megsértjük a próba feltételeit)

nem mérünk elég precízen

**Tervezzünk előre!!**

más hibák (lásd mindjárt)

Pechünk volt (mintavételi hiba, véletlen)

**-Kérdezze meg statisztikusát...**

(☺ pl: <https://www.youtube.com/watch?v=PbODigCZqL8> )




# Mintabeli érték

Populációbeli (valódi) érték

**Hibák**


Torzítás (szisztémás hiba) (bias):  
Kiválasztási hiba (Selection bias)  
Információs hiba (Information bias)  
Összemosó tényező (Confounding bias)

Mintavételből származó  
(„véletlen”) hiba  
(elemszám növelésével csökken)

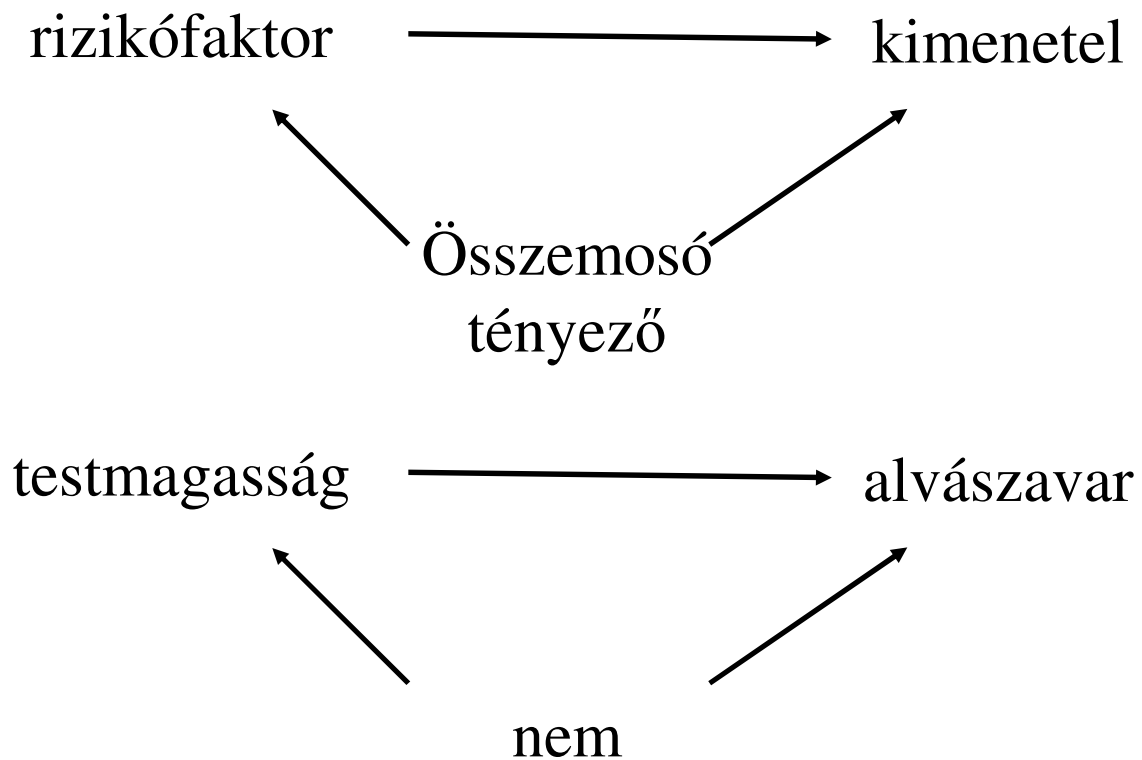




# Összemosó (megzavaró) hiba (confounding)



# Összemosó hiba



Leggyakoribbak: nem, életkor – mindig gondoljunk rá!

# Kiválasztási, Információs hiba

Kiválasztási hiba:

Különbség van a felmérésbe beválasztottak és nem beválasztottak vagy a beválasztottak csoportba sorolása között (egy kimenetelt befolyásoló paraméter tekintetében)

tipikus hibák: életkor, nem eltérő a csoportokban  
alappopuláció eltérő  
utánkövetés eltérő

Információs hiba:

Téves az alanyoktól kapott, alanyokról gyűjtött információ (, amely befolyásolja a kimenetelt)

tipikus hibák: visszaemlékezés rossz  
elfogódottság

# Ellenőrző kérdések

- Mit jelent a szisztémás és a véletlen hiba?
- Mit jelent, ha egy becslés torzítatlan?
- Mit jelent, ha egy becslés hatásos?
- Mit jelent, ha egy becslés konzisztens?
- Definiáld a konfidencia intervallumot!
- Mi a hipotézisvizsgálatok célja?
- Milyen a hipotézisvizsgálatok „jó kérdése”?
- Milyen a hipotézisvizsgálatok „jó hipotézise”:
- Mit jelent a szignifikancia szint?
- Mit jelent az, hogy egy hatás, különbség... releváns?
- Definiáld az elsőfajú hibát!
- Definiáld a másodfajú hibát!
- Fogalmazd meg a hipotézisvizsgálat p-értékének jelentését.
- Mit jelent a konfounding (összemosó) hiba?
- Mit jelent az információs és kiválasztási torzítás?