

Wilcoxon-féle előjel-próba

Példa: Van-e hatása egy szórakoztató film megtekintésének, a páciensek együttműködési hajlamára? (A számok pontértékek)

sorszám	előtte	utána	különbség
1	2	2	0
2	0	1	1
3	3	2	-1
4	2	4	2
5	1	3	2
6	3	3	0
7	1	4	3
8	1	5	4
9	5	2	-3
10	4	4	0

Normális eloszlású?



A rangok

A különbségek abszolút értékét (kivéve a 0 értékeket) állítsuk sorba! A rangoknak adjuk vissza az előjelét! Majd számoljuk ki a rangok átlagát és szórását.

különbség	abszolút érték	rang	Előjeles rang
0	0		
1	1	1,5	1,5
-1	1	1,5	-1,5
2	2	3,5	3,5
2	2	3,5	3,5
0	0		
3	3	5,5	5,5
4	4	7	7
-3	3	5,5	-5,5
0	0		



A nullhipotézis megfogalmazása

Nincs hatása a filmnek!



A medián 0!
Az eltérés csak véletlen!

$$H_0: \mu_0 = 0$$

$$H_1: \mu_0 \neq 0$$



Ismert eloszlás

De a rangok eloszlása sem ismert!



$$t = \frac{\bar{R} - 0}{s / \sqrt{n}}$$

Ha n elég nagy.

\bar{R} - az előjeles rangok átlaga
 s - a rangok szórása

Emlékeztető!
A rangok átlaga = medián



Döntés



Párosított t-próba

Ha az adatok
valamilyen szempontból
párokba rendezhetőek!

Egyazon egyeden, páros
szerven (pl. vese) végzett
két megfigyelés.

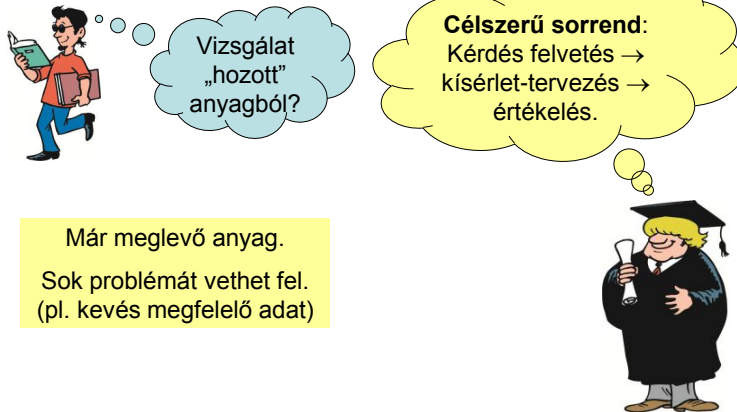
Ritkábban, szempontok
alapján (kor, foglalkozás,
stb.) párosítható adatok.

Lásd:
lázcsillapító
hatása.



Kísérlet-tervezés

Kísérlet-tervezés



Már meglevő anyag.
Sok problémát vehet fel.
(pl. kevés megfelelő adat)

„valódi” egymintás t-próba



$$t = \frac{\bar{x} - \mu_0}{s_x}$$

Ritkábban
előforduló eset.




Előjel-próba

Példa: vizsgálat 2 éves gyerekek populációjában az energia felvétel nagyságáról.

Kérdés: Lehet-e a medián

(egy másik felmérésből származó érték) 1286 kcal?

Nullhipotézis: a medián 1286 kcal, az eltérés csupán véletlen.



A vizsgálat

Kis elemszám esetében

$$P(x) = \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x}$$

binomiális eloszlás

Nagy elemszám esetében


$$z = \frac{|x - np| - 1/2}{\sqrt{np(1-p)}}$$

standard normális eloszlás

x – gyerekek száma 1286 kcal alatt
n – vizsgálatba bevont gyerekek száma
p – annak a valószínűsége, hogy véletlenül kisebb legyen (lásd: binomiális eloszlás)

A döntés

Kiszámoljuk a véletlen eltérés valószínűségét. (binomiális, vagy standard normális eloszlás)



Vizsgálat két csoportban

Kérdés: A két minta származhat-e azonos populációból, vagy a két populáció paraméterei azonosak?

paraméteres

$$\mu_1 = \mu_2 ?$$

Nullhipotézis: $\mu_1 = \mu_2$

kétmintás t-próba

nem paraméteres

Nullhipotézis: a két minta azonos populációból származik.

Mann-Whitney U-próba

kétmintás t-próba

$$\bar{x}_1 = \bar{x}_2$$



Ismert eloszlású változóra van szükség!



$$t = \frac{\bar{x}_1 - \bar{x}_2}{s^* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$


$$s^* = \sqrt{\frac{Q_1 + Q_2}{n_1 + n_2 - 2}}$$

A próba

A t-érték az t-érték!




Akkor meg tudom csinálni!
Pardon, mennyi a szabadsági fokok száma?



$$\text{sz.f.} = n_1 + n_2 - 2 \\ ((n_1 - 1) + (n_2 - 1))$$

A kétmintás t-próba feltétele

- A feladat: két egymástól **független** csoport összehasonlítása.
- A változó **normális eloszlású** legyen.
- A **szórás** a két csoportban **azonos**nak tekinthető.



Ez utóbbi új!
Hogyan állapítható meg?

A szórások vizsgálata

Hogyan fogjunk hozzá?



Nullhipotézis: a két szórás azonos, az eltérés véletlen (mintavétel).

De hiszen ez olyan, mint egy hipotézis-vizsgálat!



Az F-próba

$$F = \frac{s_1^2}{s_2^2}$$

A nullhipotézishez tartozik egy ún. F-eloszlás.



A számlálóban mindig a nagyobb variancia van! ($F \geq 1$)

De melyik variancia legyen a számlálóban?



A döntés

- 1. Ha a véletlen eltérés valószínűsége kicsi ($p(F > F_{\text{krit}}) \leq 5\%$) – **elvetjük** a nullhipotézist.
- 2. Ha a véletlen eltérés valószínűsége nagy ($p(F > F_{\text{krit}}) > 5\%$) – **megtartjuk** a nullhipotézist.

Mann-Whitney U-próba

Példa: hatásos-e a fejfájás-csillapító?

Doktor úr!
Csináljon valamit.



Hogyan mérhető a hatás?




Kísérlet

I. csoport:
(eset)
aszpirint kap




II. csoport:
(kontroll)
placebo-t kap
(hatóanyag nélküli
tabletta)



Ez egy önkényes,
folytonos skála.

Eredmények



érték	3,1	4,1	4,2	4,3	4,5	5,1	5,3	5,4	5,5
rang	1	2	3	4	5	6	7	8	9
érték	5,6	6,2	6,2	6,5	7,5	8,3	8,3	8,4	9,1
rang	10	11,5	11,5	13	14	15,5	15,5	17	18

A nullhipotézis megfogalmazása

a „gyógyszer” nem hatásos.

A két csoport azonos populációhoz tartozik.



A rangok összege (avagy a kis Gauss esete a tanárral)

Gyerekek! Adjátok össze a számokat 1-től százig.

Miért adjam össze? Könnyebben is kiszámolható!

$$1 + 100 = 101 \\ 2 + 99 = 101 \dots$$

$$\sum_{i=1}^n i = \frac{n}{2} \cdot (n+1)$$



A „nagy átalakítás”

T – a rangok összege az I. csoportban, véletlen eloszlás esetén a várható értéke:

A z változó standard normális eloszlású. (ha n elég nagy)


$$n_1 \cdot \frac{n_1 + n_2 + 1}{2}$$

$$z = \frac{T - n_1(n_1 + n_2 + 1)/2}{s}$$

$$s = \sqrt{\frac{n_1 \cdot n_2 \cdot (n_1 + n_2 + 1)}{12}}$$



Döntés




A kiszámolt z-érték: 3,24.
Ez nagyobb, mint az 1,96.

Következtetés: a nullhipotézist elvetjük.

Kiszámolt p-érték $< 0,1\%$.
Következtetés hasonló a fentihez.

Variancia-analízis (ANOVA)



Miért nem csinálunk kétmintás t-próbákat?


Mert a tévedés lehetősége nagyon megnőne!



A – B és B – C valamint
A – C összehasonlítása. (nem tranzitív)



Mekkora a tévedés esélye?



p – annak a valószínűsége, hogy kívül van $(1-p)$ – annak, hogy belül van az érték véletlenül.

Tételezzük fel, hogy mindhárom esetben elvetjük a nullhipotézist.



Kérdés: Mekkora az esélye, hogy legalább egy esetben tévedtünk?

Mekkora az esélye, hogy legalább egy kívül essen véletlenül?



Egy próba esetében ez p (legyen 5%). Több próba esetében a binomiális eloszlás adja meg.

$$1 - (1 - p)^3$$

Ez ebben az esetben kb. 15%!!!



Több csoport



A csoportokat kezelhetjük külön-külön és együtt.




Csoportátlag: a csoport elemeiből számolt átlag.

Nagyátlag: a teljes adathalmazból számolt átlag.



A variancia összetevői



Emlékeztető:

A variancia arányos az átlagtól való eltérések négyzetösszegével!




Ha a csoportok jelentősen különböznek egymástól, a nagyátlagtól való átlagos eltérések jóval nagyobbak, mint a csoporton belül a csoportátlagtól való eltérések!

Az ANOVA alapja



Ebben az esetben nem olyan nagy a különbség!

A teljes variancia (a nagyátlagtól vett eltérésekből számolt) a csoportokon belüli és a csoportok közötti varianciából tevődik össze!



A variancia felbontása (nem kell tudni)

Legyen N adat k csoportban.

x_{ij} – a j -edik adat az i -edik csoportban,

n_i – az elemek száma az i -edik csoportban

nagyátlag
$$\bar{x} = \frac{\sum_{i,j} x_{ij}}{N}$$

csoportátlag
$$\bar{x}_i = \frac{\sum_j x_{ij}}{n_i}$$

$$(x - x_{ij}) = (x - \bar{x}_i) + (\bar{x}_i - x_{ij})$$

az adat eltérése a nagyától a csoportátlag eltérése az adat eltérése a csoportától

Emeljük négyzetre!

$$(x - x_{ij})^2 = (x - \bar{x}_i)^2 + (\bar{x}_i - x_{ij})^2 + 2(x - \bar{x}_i)(\bar{x}_i - x_{ij})$$

$$\sum (x - x_{ij})^2 = \sum (x - \bar{x}_i)^2 + \sum (\bar{x}_i - x_{ij})^2 + \sum 2(x - \bar{x}_i)(\bar{x}_i - x_{ij})$$

kovariancia = 0 (függetlenek)

$$\sum 2(x - \bar{x}_i)(\bar{x}_i - x_{ij}) = 0$$

$$\sum (x - x_{ij})^2 = \sum (x - \bar{x}_i)^2 + \sum (\bar{x}_i - x_{ij})^2$$

Csoportok közötti

Csoporton belüli

A variancia felbontható komponensekre!

A nullhipotézis

A csoportok között nincs különbség.

A csoportok átlagai közötti eltérés csupán a véletlen műve.



Döntés: a csoportok közötti és a csoporton belüli varianciák összehasonlítása alapján.



A varianciák kiszámolása

A variancia	négyzetösszeg	szab. fok		F érték
csoportok között	$SS_A = \sum_j n_j (\bar{x}_j - \bar{x})^2$	$k-1$	$MS_A = \frac{SS_A}{k-1}$	$F = \frac{MS_A}{MS_E}$
csoporton belül	$SS_E = SS_T - SS_A$	$N-k$	$MS_E = \frac{SS_E}{N-k}$	
teljes	$SS_T = \sum_{i,j} (x_{i,j} - \bar{x})^2$	$N-1$		

k – a csoportok száma

A döntés

- 1. Ha a véletlen eltérés valószínűsége kicsi ($p(F > F_{\text{krit}}) \leq 5\%$) – **elvetjük** a nullhipotézist.
- 2. Ha a véletlen eltérés valószínűsége nagy ($p(F > F_{\text{krit}}) > 5\%$) – **megtartjuk** a nullhipotézist.

(A döntés után, ha szükségesnek tartjuk, csinálhatunk t -próbákat)

Kruskal-Wallis próba

Az adatokat a csoportoktól függetlenül rangsoroljuk! Az így kapott rangokat a csoportokon belül összegezzük!



Ha a változó
nem normális eloszlású!

A nullhipotézis

A csoportok között nincs
különbség.



A rangok összege közötti
eltérés csupán a véletlen
műve.



Milyen eloszlást használjunk?

$$H = \frac{12}{N(N+1)} \sum_i \frac{R_i^2}{n_i} - 3(N+1)$$

N – az elemek száma
 R_i – a rangok összege az i -edik csoportban
 n_i – az elemek száma az i -edik csoportban

Közjáték (nem kell megtanulni)

$$H = \frac{12}{N(N+1)} \sum_i \frac{R_i^2}{n_i} - 3(N+1)$$

$$\rightarrow \sum_i \frac{R_i^2}{n_i} = \sum_i n_i \left(\frac{R_i}{n_i} \right)^2 = \sum_i n_i R_i^2$$

A rangok
átlaga:

$$\bar{R}_i = \bar{R} + \Delta_i$$

Δ_i – az i-edik csoport átlagának eltérése
a főátlagtól ($\sum \Delta_i = 0$)

$$\bar{R} = \frac{N(N+1)}{2N} = \frac{N+1}{2}$$

$$\rightarrow \sum_i n_i R_i^2 = \bar{R}^2 \sum_i n_i + \sum_i n_i \Delta_i^2 + 2\bar{R} \sum_i n_i \Delta_i (=0)$$

$$\sum_i n_i R_i^2 = \frac{(N+1)^2}{4} N + \sum_i n_i \Delta_i^2$$


$$H = \frac{12}{N(N+1)} \left(N \frac{(N+1)^2}{4} + \sum_i n_i \Delta_i^2 \right) - 3(N+1)$$

$$\rightarrow H = \frac{12}{N(N+1)} \sum_i n_i \Delta_i^2$$

A χ^2 -eloszlás

A H értéke ≥ 0 !

A H változó
 χ^2 -eloszlást
követ!



A döntés

- 1. Ha a véletlen eltérés valószínűsége kicsi ($p(\chi^2 > \chi^2_{\text{krit}}) \leq 5\%$) – **elvetjük** a nullhipotézist.
- 2. Ha a véletlen eltérés valószínűsége nagy ($p(\chi^2 > \chi^2_{\text{krit}}) > 5\%$) – **megtartjuk** a nullhipotézist.

Hipotézis
vizsgálat?

- Felállítjuk a **nullhipotézist**.
- Keresünk egy **ismert eloszlású változót**.
- Az eloszlás alapján kiszámoljuk a **véletlen eltérés valószínűségét**.
- Ha ez kisebb mint a szignifikancia szint **elvetjük**, ellenkező esetben **megtartjuk a nullhipotézist**.
- Ennyi!

