

To-utvalg permutasjonstest

TMA4240/TMA4245 Statistikk

Håkon Tjelmeland

Institutt for matematiske fag

Norges teknisk-naturvitenskapelige universitet

To-utvalg permutasjonstest

- ★ Anta
 - vi er gitt $n + m$ pasienter (ikke tilfeldig trukket)
 - to behandlinger: tradisjonell behandling og ny behandling
 - ønsker å vite om ny behandlingen er bedre enn den tradisjonelle
 - når en pasient har fått behandling kan vi observere en størrelse x
 - anta at lav verdi av x er ønskelig
 - f. eks: x er rekonalenstid
 - f. eks: x er mål på hvor mye bivirkninger man opplever
 - formulerer problemet som en hypotesetest
- ★ Hypoteser: H_0 : effekten av behandlingene er like mot H_1 : ny behandling er bedre
- ★ Stokastisk forsøk:
 - trekker tilfeldig n pasienter fra de $n + m$ pasientene tilgjengelige
 - de n pasientene vi trakk ut får tradisjonell behandling
 - de resterende m pasientene får ny behandling
 - observerer størrelsen x for hver av de $n + m$ pasientene
- ★ Stokastiske variabler:
 - X_1, \dots, X_n : observerte verdier for pasienter som får tradisjonell behandling
 - $X_{n+1}, X_{n+2}, \dots, X_{n+m}$: observerte verdier for pasientene som får ny behandling
- ★ Merk:
 - X_1, X_2, \dots, X_{n+m} er stokastiske fordi vi randomiserer behandlingen
 - en indikator for om den nye behandlingen er bedre enn den gamle kan være
- stor verdi for U indikerer at ny behandlingen er best
- ★ Kan vi bruke U som testobservator?

Hvilken fordeling har U når H_0 er sann?

* Husk:

- H_0 : effekten av behandlingene er like
- definisjonen av U

$$U = \frac{1}{n} \sum_{i=1}^n X_i - \frac{1}{m} \sum_{i=n+1}^{n+m} X_i$$

- U er stokastisk fordi vi har trukket tilfeldig hvem som får hvilken behandling

* Hvis H_0 sann:

- vi observerer de samme verdiene uansett type behandling
- U er likevel stokastisk

* Lekeksempel: Anta $n = 3$, $m = 2$, altså $n + m = 5$ pasienter

- antall mulige inndelinger av 5 pasienter i to grupper, 3 i den første og 2 i den andre

$$\binom{5}{3,2} = \frac{5!}{3! \cdot 2!} = 10$$

pasient id	verdi	1	②	3	4	5	6	7	8	9	10
i	12.03	t	t	t	t	t	t	n	n	n	n
ii	9.94	t	t	t	n	n	n	t	t	t	n
iii	10.24	t	n	n	t	t	n	t	t	n	t
iv	11.49	n	t	n	t	n	t	t	n	t	t
v	8.82	n	n	t	n	t	t	n	t	t	t
verdi for u		0.58	1.62	-0.60	1.87	-0.35	0.69	0.13	-2.09	-1.05	-0.80

* Husk: stor verdi for U indikerer at ny behandling er best

* p-verdien blir: $p = P(U \geq 1.62 | H_0 \text{ sann}) = \frac{2}{10} = 0.2$

To-utvalg permutasjonstest

- ★ Anta $n + m$ pasienter totalt
 - n pasienter får tradisjonell behandling
 - m pasienter får ny behandling
- ★ Antall mulige inndelinger av $n + m$ pasienter i to grupper, n i første og m i andre

$$\binom{n+m}{n, m} = \frac{(n+m)!}{n! \cdot m!}$$

- ★ La u^* være observert verdi for testobservator
- ★ La $u_i, i = 1, 2, \dots, \binom{n+m}{n, m}$ være verdi for testobservator for hver av de mulige inndelingene i to grupper
- ★ Anta stor verdi av testobservator indikerer at H_1 er korrekt
- ★ p-verdien blir

$$p = \frac{1}{\binom{n+m}{n, m}} \sum_{i=1}^{\binom{n+m}{n, m}} \mathbb{I}(u_i \geq u^*)$$

- ★ MEN: Hva gjør vi hvis $n + m$ er stor?
 - eksempel: $n = 20, m = 23$
- ★ Kan estimere p-verdien ved stokastisk simulering!

$$\binom{43}{20, 23} = \frac{43!}{20! \cdot 23!} = 960\,566\,918\,220$$

To-utvalg permutasjonstest og stokastisk simulering

- ★ Anta $n + m$ pasienter totalt
 - n pasienter får tradisjonell behandling
 - m pasienter får ny behandling
- ★ Antall mulige inndelinger av $n + m$ pasienter i to grupper, n i første og m i andre

$$\binom{n+m}{n, m} = \frac{(n+m)!}{n! \cdot m!}$$

- ★ La u^* være observert verdi for testobservator
- ★ Trekk tilfeldig s gruppeinndelinger (uavhengig av hverandre)
 - la u_i være verdi av testobservator ved å bruke i -te gruppeinndeling
- ★ Vi har da $s+1$ verdier av testobservatoren: $u^*, u_1, u_2, \dots, u_s$
- ★ Anta stor verdi av testobservator indikerer at H_1 er korrekt
- ★ Estimert verdi for p-verdien blir

$$\hat{p} = \frac{1}{s+1} \left(1 + \sum_{i=1}^s \mathbb{I}(u_i \geq u^*) \right)$$

Oppsummering

- ★ Har sett på to-utvalg permutasjonstest
 - antar ingenting om type fordeling av observasjoner
 - det er (vår) tilfeldige inndeling i grupper som gir tilfeldighet
 - testobservatoren er en diskret stokastisk variabel

- ★ Hvis antall mulige gruppeinndelinger er veldig stor
 - ikke overkommelig å beregne eksakt p-verdi
 - kan estimere p-verdien ved stokastisk simulering