

James Robins g-formulája

KBT előadás, Lang Zsolt

Budapest, 2021. november 12.

Oksági következtetés longitudinális megfigyeléses adatokból

Megfigyeléses kohorsz vizsgálatok

Időben és betegenként változó kezelések

- Bizonyos időszakban van, máskor nincs
- A kezelések fajtái változnak
- A dózis változik
- Időben változó értékű **kovariánsok befolyásolják** a következő kezelés allokálását
- Az aktuális **kezelés hatással van az időtől függő kovariánsok későbbi értékére**

A megfigyelési időszak végén valamilyen esemény következik be

- Betegség alakul ki, gyógyulás/halálozás történik
- Folytonos skálájú jellemzőt mérünk meg

Egyszerű(bb) verzió

Feltesszük, hogy a kezelés allokálása szekvenciálisan figyelmen kívül hagyható, azaz

$$Y_a \perp\!\!\!\perp A(t) \mid \underline{L}(t), \underline{A}(t-1).$$

A g-formula az Y_a **counterfactual célváltozó várható értékét** számolja ki az $Y_A, \underline{A}(t), \underline{L}(t)$ **megfigyelt adatokból**.

Megjegyzés: az allokálás szekvenciálisan figyelmen kívül hagyható ugyanaz, mint hogy nincs hiányzó kovariáns. A cikk függelékében „**exchangeability**”-nek nevezték.

Állítás (g-formula)

$$E(Y_{\underline{a}}) = \int \dots \int E(Y_{\underline{A}} | \underline{L}(K) = \underline{l}_K, \underline{A}(K) = \underline{a}_K) \cdot \prod_{k=0}^K f(l_k | l_{k-1}, a_{k-1}) d\mu(l_k).$$

Bizonyítás:

$$E(Y_{\underline{a}}) = E\left(E(Y_{\underline{a}} | L_0, A_0)\right) = \int E(Y_{\underline{a}} | L_0 = l_0, A_0 = a_0) \cdot f(l_0) d\mu(l_k),$$

üi. $E(Y_{\underline{a}} | L_0 = l_0, A_0 = a_0) = E(Y_{\underline{a}} | L_0 = l_0)$.

Hasonló összefüggést írhatunk fel $E(Y_{\underline{a}} | L_0 = l_0, A_0 = a_0)$ -ra, rétegezve az első időpontban. Ezt folytatva kapjuk, hogy

$$E(Y_{\underline{a}}) = \int \dots \int E(Y_{\underline{a}} | \underline{L}(K) = \underline{l}_K, \underline{A}(K) = \underline{a}_K) \cdot \prod_{k=0}^K f(l_k | l_{k-1}, a_{k-1}) d\mu(l_k).$$

Igen ám, de $E(Y_{\underline{a}} | \underline{L}(K) = \underline{l}_K, \underline{A}(K) = \underline{a}_K) = E(Y_{\underline{A}} | \underline{L}(K) = \underline{l}_K, \underline{A}(K) = \underline{a}_K)$.

Ebben a g-formula verzióban az $\underline{a} = \underline{a}_K = (a_0, a_1, \dots, a_K)$ terápiasorozat előre adott, nem függ a véletlentől. Ez az ún. **statikus determinisztikus** változat.

A g-formula általánosításában az időben k -adik a_k counterfactual (tényellentétes) terápiát egy előre adott „önkényes”

$$f^{int}(a_k | \underline{l}_k, \underline{a}_{k-1})$$

feltételes eloszlásból sorsoljuk ki, ismertnek feltételezve az adott k időpontig az összes \underline{l}_k kovariánst és a $k - 1$ -ik időpontig az összes előző \underline{a}_{k-1} terápiát.

Több változata ismert:

- ❖ **determinisztikus**, ha f^{int} elfajuló eloszlás, vagyis nincs sorsolás,
- ❖ ha nem determinisztikus, akkor **random**,
- ❖ **statikus**, ha a_k nem függ az \underline{l}_k kovariánsoktól, azaz pontosabban $f^{int}(a_k | \underline{l}_k, \underline{a}_{k-1}) = f^{int}(a_k | \underline{a}_{k-1})$,
- ❖ ha nem statikus, akkor **dinamikus**.

A g-formula általános alakja

Állítás:

$$E(Y) = \int \dots \int E(Y_{\underline{A}} | \underline{L}(K) = \underline{l}_K, \underline{A}(K) = \underline{a}_K) \cdot \prod_{k=0}^K f(l_k | l_{k-1}, \underline{a}_{k-1}) \cdot f^{int}(a_k | l_k, \underline{a}_{k-1}) d\mu(l_k, a_k).$$

A bizonyítás a speciális eset kis módosításával kapható meg.