



## P. KLÁŠTERECKÝ & M. KULICH

# LOGISTICKÁ REGRESE V SUBKOHORTNÍCH STUDIÍCH

### DNES V LISTU:

- Co jsou subkohortní studie, k čemu slouží a jak se pracuje s jejich daty
- Proč někdy nefungují tak dobře, jak by měly
- A nakonec jeden nápad, jak by se to dalo spravit

### DÁLE SI NENECHTE UJÍT:

- Podrobný popis použitých metod a modelů
- Přiměřené množství důkazního materiálu a samozřejmě závěrečnou diskusi
- ! Vychází již v letošním sborníku !

### Subkohortní studie

Klasické kohortní studie mohou být např. při zkoumání vzácných onemocnění velmi drahé – pro zajištění dostatečného počtu událostí ve výběru je často nutné sledovat i obrovskou kontrolní skupinu. Subkohortní (case-cohort) studie typicky pracuje pouze s náhodně vybranou malou částí původní cohorts, subkohortou, ke které se navíc přidají všechny pozorované události. Ze vám to něco připomíná? Studie typu case-control?

### Jak to funguje?

Celkem jednoduše. Data se obvykle analyzují regresním modelem, pro odhad jeho parametrů se vezmou skórové (odhadovací) rovnice známé z klasické analýzy přežívání a místo běžného součtu příspěvků od jednotlivých pozorování se použije součet vážený. Váhy pro pozorování mimo subkohortu se obvykle volí nulové (abychom nepočítali s neznámými hodnotami), pro ostatní pozorování potom  $1/p_i$ , kde  $p_i$  je pravděpodobnost výběru do subkohorty.

Asymptotické vlastnosti subkohortních odhadů však platí pouze za předpokladu, že  $p_i \geq \varepsilon > 0$ . Pro velmi malé pravděpodobnosti (stačí již  $p_i \sim 10^{-3}$ ) začínají mít odhadovací vychýlení a jejich intervaly spolehlivosti slabší pokrytí – viz následující příspěvek na minulém Robustu. Jelikož je kontrolní pozorování často řádově mnohem méně než  $n$  (počet jednotlivých pozorování), může být odhad subkohorty výrazně odlišný od odhadu kohorty. Tento fakt je významný pro výběr subkohorty, protože odhad subkohorty je významně ovlivněn tím, zda je výběr výhodný pro kohortu.

### Studie typu case-control

podobnými problémy netrpí, protože poměr šancí odhadovaný logistickou regresí lze určit i z takto nevyváženého výběru bez použití vah pro jednotlivá pozorování. Absolutní člen z těchto dat odhadnout nelze, ale ve většině případů jej odhadovat nepotřebujeme.

Uvažujme pro doby do události model proporcionálních šancí, který lze zapsat ve tvaru

$$-\text{logit}(S(t|\mathbf{Z})) = G(t) + \boldsymbol{\beta}' \mathbf{Z},$$

kde  $S(t)$  značí pravděpodobnost přežití v čase  $t$  a  $\text{logit}(x) = \log(x/(1-x))$ . Neznámé parametry jsou zde  $G(t) = -\text{logit}(S(t|\mathbf{Z} = \mathbf{0}))$ , referenční logaritmická šance výskytu události v čase  $t$ , a vektor regresních koeficientů  $\boldsymbol{\beta}$ . Model předpokládá, že poměr šancí na přežití

(survival odds ratio) mezi dvěma libovolnými subjekty, vyjádřený pomocí  $\boldsymbol{\beta}$ , zůstává v čase konstantní.

V subkohortní studii máme k dispozici informaci o časech událostí nebo cenzorování. Když bychom ale znali pouze indikátory výskytu sledované události v nějakém čase  $\tau_0$ , použili bychom logistickou regresi se stejným tvarem modelu, jen místo funkcí bychom dosadili konstanty  $S(\tau_0|\mathbf{Z})$  a  $G(\tau_0) = \alpha(\tau_0)$ . To se bude hodit ...

### Spojitost mezi oběma typy studií

### Využití logistické regrese

#### Předpoklad neměnnosti odhadovaného poměru šancí

- ⇒ model proporcionálních šancí odhaduje stejné regresní parametry  $\boldsymbol{\beta}$  jako case-control logistická regrese provedená na konci studie
- ⇒ analýzu pomocí logistické regrese lze provést i v jiných časech než na konci studie a stále bude konzistentně odhadovat stejné parametry
- ⇒ získané odhady můžeme zkombinovat do jednoho a zachytit tak časovou informaci, která se při použití logistické regresy ztrácí

#### Kombinovaný odhad

- Výsledný odhad definujeme jako takovou konvexní lineární kombinaci dílčích logistických odhadů, která minimalizuje rozptyl
- Kombinovaný odhad je konzistentní a asymptoticky normální
- Dílčí logistické analýzy je nevhodnější provádět v časech událostí, kde se mění hodnota skokové věrohodnostní funkce v modelu prop. šancí
- Při velmi malých pravděpodobnostech události odhadnutý poměr šancí dobře approximuje relativní riziko ⇒ použitelnost i pro Coxův model

### Sečteno a podtrženo

Nový odhad regresních parametrů pro model proporcionálních šancí funguje na principu zkombinování několika postupných odhadů stejných parametrů logistickou regresí. Jeho uplatnění předpokládáme zejména v subkohortních studiích s velmi řídkými jevy, kde v simulačních studiích vykazuje lepší vlastnosti než odhady dosud používané a navíc může posloužit jako

dobrá approximace i pro známější a používanější model proporcionálních rizik.

Odhad byl prozatím odvozen a zkouman při jednoduchém cenzorování konstantou (koncem studie). V dalším výzkumu je třeba věnovat pozornost především jeho chování při obecnějších typech cenzorování.