

Zobecněné lineární modely pro značkované bodové procesy

David Kraus

ÚTIA AV ČR Praha & KPMS MFF UK Praha, kraus@karlin.mff.cuni.cz, <http://www.karlin.mff.cuni.cz/~kraus/robust2006/>Motto: *Mladá nadějná generace hodně pochytila od svých učitelů a daří se jí slibně komplikovat jednoduché úlohy.*
Jiří Žváček v hodnocení ROBUSTu 2004
<http://www.stahroum.me.cz/euje/robust2004/>

1 Úvod

Uvažujme longitudinální pozorování

$$T_{ij}, Z_i(T_{ij}), (X_{i1}(T_{ij}), \dots, X_{ip}(T_{ij}))^\top, j = 1, 2, \dots,$$

tedy pro i -tého jedince pozorujeme v náhodných časech $T_{i1} < T_{i2} < \dots$ značky $Z_i(T_{ij})$ a kovariáty $(X_{i1}(T_{ij}), \dots, X_{ip}(T_{ij}))^\top$. Cílem je modelovat závislost rozdělení značek na kovariátech pomocí *zobecněných lineárních modelů* (GLM) s časově závislými koeficienty.

2 Značkované bodové procesy

Dvojice $T_{ij}, Z_i(T_{ij})$ tvoří *značkovaný bodový proces* (MPP) v časovém intervalu $[0, \tau]$ se značkami v nějakém prostoru E (Brémaud, 1981). Proces označme $p_i(dt \times dz_i)$. Jedná se o náhodnou čítací míru na $[0, \tau] \times E$. Proces $p_i(dt \times A) = \int_A p_i(dt \times dz_i)$ (A je nějaká borelovská množina) je čítací proces adaptovaný na nějakou filtraci, tzn. $p_i(dt \times A)$ počítá události se značkami v A .

Chování procesu je popsáno jádrem intensity

$$\lambda_i(t, dz_i) = \lambda_i(t)\Phi_i(t, dz_i).$$

Zde $\lambda_i(t)$ je *intensita* procesu $p_i(dt \times E)$ (proces všech událostí bez ohledu na jejich značky). $\Phi_i(t, dz_i)$ je *podmíněné rozdělení značek* v čase t za podmínky historie do t a toho, že t je časem pozorování.

3 GLM pro MPP

Modelujme rozdělení $\Phi_i(t, dz_i)$ pomocí GLM. Předpokládejme, že jeho střední hodnota $\mu_i(t)$ závisí na lineárním prediktoru $\eta_i(t) = X_i(t)^\top \beta(t)$ pomocí linkové funkce g , čili

$$g(\mu_i(t)) = \eta_i(t) = X_i(t)^\top \beta(t).$$

Rozptyl v rozdělení $\Phi_i(t, dz_i)$ předpokládejme ve tvaru $\psi(t)V(\mu_i(t))$, kde $\psi(t)$ je dispersní parametr a $V(\mu)$ je varianční funkce. Jak koeficienty $\beta(t)$, tak disperse $\psi(t)$ mohou záviset na čase (uvažujeme *neparametrický model*). Speciálním případem je lineární model, který uvažovali Martinussen & Scheike (2001).

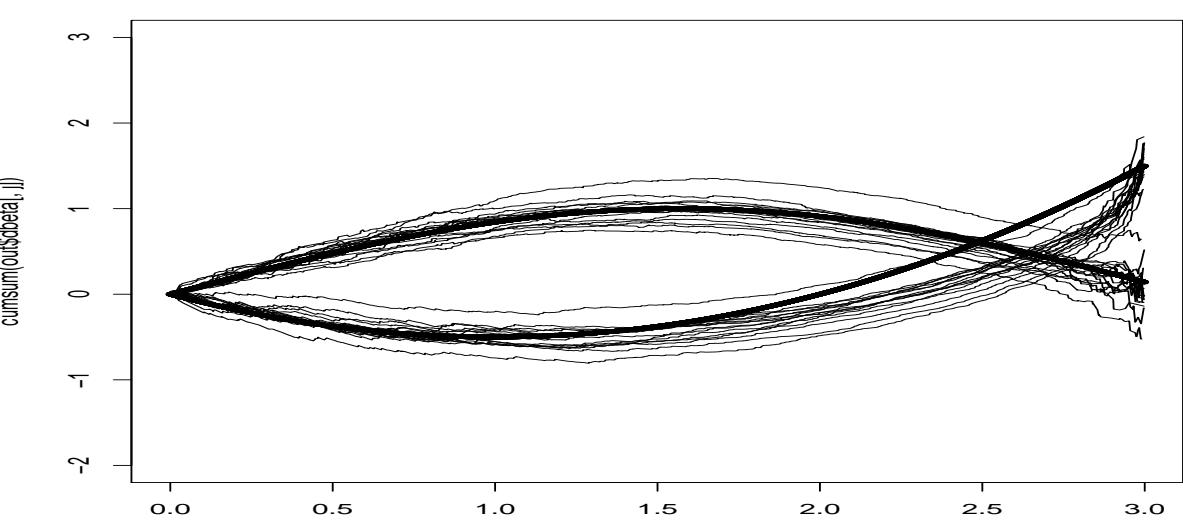
4 Odhad

Odhadneme kumulativní koeficienty $B(t) = \int_0^t \beta(s)ds$. Proč *kumulativní*? Abychom mohli o nich dělat inferenci. Předpokládejme, že intensita $\lambda_i(t)$ splňuje Aalenův aditivní model, tj. $\lambda_i(t) = Y_i(t)U_i(t)^\top \alpha(t)$, kde $U_i(t)$ jsou nějaké kovariáty a $\alpha(t)$ koeficienty. Proč *předpokládáme nějaký model intensity časového procesu*? Protože chceme odhadovat kumulativní efekty $B(t)$, nikoli $\beta(t)$.

7 Ilustrace: odhad a testy

Obrázky 1–3 ukazují fungování *odhadů* na simulovaných datech. Silnou čárou jsou znázorněny skutečné funkce $B_1(t)$ a $B_2(t)$, tenkou čárou 15 odhadů z 15 vygenerovaných výběrů (každý o rozsahu 100). Ve všech případech je kovariáta $X_1 = 1$ a $X_2 \sim U(-2, 2)$. Intensita je konstantní $\lambda(t) = 2$.

Obr. 1: Poissonovská regrese s (kanonickým) linkem $g(\mu) = \log \mu$; $\beta_1(t) = t - 1$, $B_1(t) = t^2/2 - t$, $\beta_2(t) = \cos t$, $B_2(t) = \sin t$.



Odhadovací rovnici je

$$\sum_{i=1}^n \frac{X_i(t)}{g'(\mu_i(t))\psi(t)V(\mu_i(t))} \left[\int_E z_i p_i(dt \times dz_i) - \hat{\lambda}_i(t)\mu_i(t)dt \right] = 0$$

($\hat{\lambda}_i(t)$ se získá standardně vyhlazením odhadu z Aalenova modelu). *Kde se rovnice vzala?* Lze ji motivovat jako *kvantitativě rohodnostní rovnici*, poněvadž

$$\frac{X_i(t)\lambda_i(t)}{g'(\mu_i(t))} = \frac{\partial}{\partial \beta(t)} \mathbb{E} \left[\int_E z_i p_i(dt \times dz_i) \mid \mathcal{F}_{t-} \right] = \frac{\partial}{\partial \beta(t)} \lambda_i(t)\mu_i(t)dt$$

a

$$\psi(t)V(\mu_i(t))\lambda_i(t)dt = \text{var} \left[\int_E z_i p_i(dt \times dz_i) \mid \mathcal{F}_{t-} \right].$$

K rovnici lze dojít také z věrohodnosti spočtením skorových operátorů.

5 Algoritmus: IRLS s vyhlazováním

Rovnici řešíme pomocí *iterativně vážených nejmenších čtverců* (IRLS), přičemž mezi jednotlivými kroky spočtené přírůstky *vyhladíme* (jádrové). Odhad je inspirován metodou popsanou v Martinussen, Scheike & Skovgaard (2002). *Proč vyhlazujeme?* Iterovat v každém bodě pozorování odděleně nemůžeme, protože v každém bodě je nejvíce jedno pozorování.

Označme $\tilde{B}(t)$ předchozí odhad. Průběh iterace:

- (1) Vyhlazením $\tilde{B}(t)$ získej $\tilde{\beta}(t)$.
- (2) Spočti 1 krok IRLS pro všechny časy pozorování $t \in [0, \tau]$:

(2i) Spočti pracovní odezvu (working response)

$$\tilde{r}_i(t)dt = \tilde{\eta}_i(t)dt + \frac{g'(\tilde{\mu}_i(t))}{\hat{\lambda}_i(t)} \left[\int_E z_i p_i(dt \times dz_i) - \hat{\lambda}_i(t)\tilde{\mu}_i(t)dt \right].$$

(2ii) Spočti váhovou matici $W(t) = \text{diag}[W_i(t)]$, kde

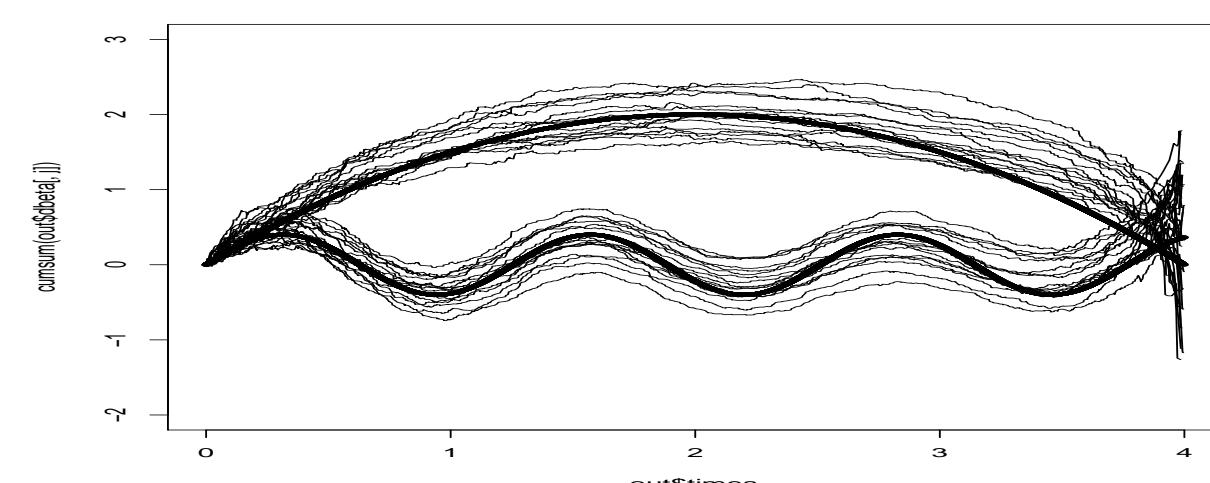
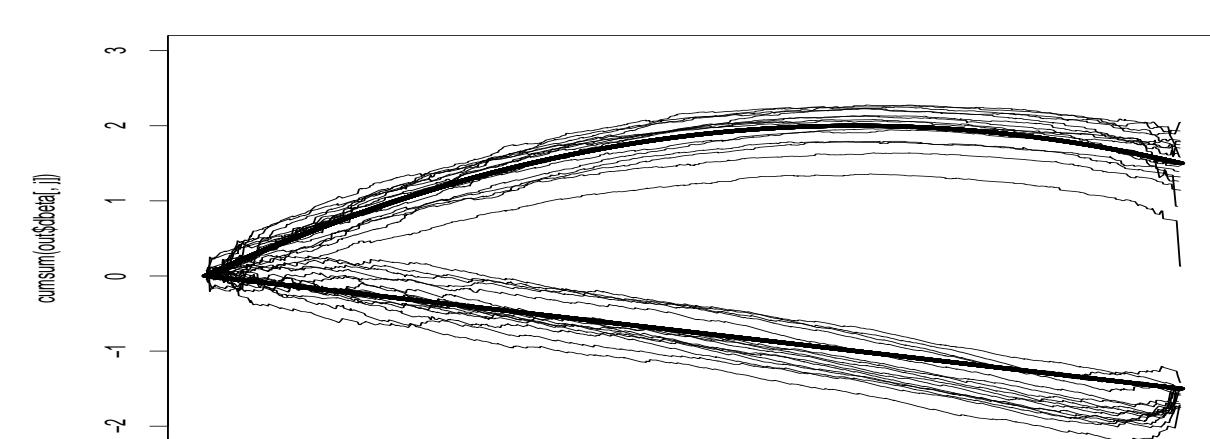
$$W_i(t) = \frac{\hat{\lambda}_i(t)}{g'(\tilde{\mu}_i(t))^2 V(\tilde{\mu}_i(t))}.$$

(2iii) Lineární regresí $\tilde{r}(t)dt$ na $X(t)$ pomocí vážených nejmenších čtverců získej přírůstky nové iterace $d\tilde{B}(t)$

$$\begin{aligned} d\tilde{B}(t) &= [X(t)^\top W(t) X(t)]^{-1} X(t)^\top W(t) \tilde{r}(t)dt \\ &= \tilde{\beta}(t)dt + [X(t)^\top W(t) X(t)]^{-1} X(t)^\top W(t) \\ &\quad \times \text{diag} \left[\frac{g'(\tilde{\mu}_i(t))}{\hat{\lambda}_i(t)} \right] \left[\int_E z_i p_i(dt \times dz_i) - \hat{\lambda}_i(t)\tilde{\mu}_i(t)dt \right]. \end{aligned}$$

(3) Jdi na (1).

Algoritmus je pochopitelně nutné někde nastartovat: například z lokálně polynomálního odhadu $\beta(t)$ (zde je použit lokálně konstantní odhad).

Obr. 2: Normální regrese s linkem $g(\mu) = \mu$; $\beta_1(t) = 2 \cos 5t$, $B_1(t) = 2 \sin(5t)/5$, $\beta_2(t) = 2 - t$, $B_2(t) = 2 - 0.5(t-2)^2$.Obr. 3: Poissonovská regrese s linkem $g(\mu) = \log \mu$; $\beta_1(t) = -0.5$, $B_1(t) = -0.5t$, $\beta_2(t) = 2 - t$, $B_2(t) = 2 - 0.5(t-2)^2$.

6 Testování konstantnosti

Testujme *konstantnost* funkcí $\beta(t)$ proti alternativě závislosti efektů na čase. Konstantnost $\beta(t)$ je ekvivalentní linearitě $B(t)$. Test (typu KS, například) můžeme založit na procesu

$$\hat{B}(t) - \frac{t}{\tau} \hat{B}(\tau).$$

K approximaci jeho rozdělení použijeme modifikaci *simulační metody* Lin, Wei & Ying (1993) původně navržené pro čítací procesy.

Pro proces $R(t) = \hat{B}(t) - B(t)$ za určitých předpokladů platí

$$R(\cdot) = \int_0^\cdot \int_E H(s, z)^\top q(ds \times dz) + o_P(n^{-1/2}),$$

kde $q_i(dt \times dz_i) = p_i(dt \times dz_i) - \lambda_i(t)\Phi_i(t, dz_i)$ jsou martingaly a $H(s, z)$ je $(n \times p)$ -matice nějakých predikovatelných procesů.

V této *martingalové representaci* můžeme *odhadnout*. Jediné, co nemůžeme pozorovat ani *odhadnout*, jsou martingaly $q_i(dt \times dz_i)$. Nahradíme je v každém okamžiku pozorování T_{ij} simulovanými hodnotami $q_i^*(dt \times dz_i) = G_{ij}p_i(dt \times dz_i)$, kde G_{ij} jsou iid $N(0, 1)$ nezávislé na datech. *Proč to funguje?* Protože limita podmíněného rozdělení (při datech) takto vyroběného procesu $R^*(t)$ je stejná jako limitní rozdělení procesu $R(t)$.

Generováním vhodného počtu realisací $R^*(t)$ můžeme procesem $R^*(t) - \frac{t}{\tau} R^*(\tau)$ approximovat rozdělení testového procesu $R(t) - \frac{t}{\tau} R(\tau)$.

Poděkování a prosba

Poděkování. Děkuji za podporu, jíž se mi dostalo prostřednictvím grantů 201/05/H007 a 402/04/1294.

Prosba. Pokud by někdo měl reálná data zde popsaného typu a byl mi je ochoten poskytnout, byl bych mu velice vděčný.

Odkazy

Brémaud, P. (1981). *Point Processes and Queues. Martingale Dynamics*. Springer, New York.

Lin, D. Y., Wei, L. J. & Ying, Z. (1993). Checking the Cox model with cumulative sums of martingale-based residuals. *Biometrika*, 80, 557–572.

Martinussen, T. & Scheike, T. H. (2001). Sampling adjusted analysis of dynamic additive regression models for longitudinal data. *Scand. J. Statist.*, 28, 303–323.

Martinussen, T., Scheike, T. H. & Skovgaard, I. M. (2002). Efficient estimation of fixed and time-varying covariate effects in multiplicative intensity models. *Scand. J. Statist.*, 29, 57–74.

Obrázek 4 ukazuje *testy konstantnosti* regresních funkcí $\beta_1(t)$ a $\beta_2(t)$ pro výběr o rozsahu 100 vygenerovaný z modelu z obr. 3. Silná čára zachycuje testový proces, slabé čáry 50 simulovaných trajektorií z rozdělení testového procesu za platnosti hypotézy konstantnosti.

Obr. 4: Test konstantnosti $\beta_1(t)$ (nahoře) a $\beta_2(t)$.