

Regrese v modelech oprav

Petr Novák

KPMS MFF UK

11. září 2012

- Studujeme data o historii zařízení, které podléhá opotřebení.
- Když se porouchá, je nutné provést opravu.
- Poruchám se snažíme předcházet preventivní údržbou.
- T_1, \dots, T_n časy zásahů (oprav nebo údržeb).
- $\Delta_1, \dots, \Delta_n$ indikátor zda v j -tém čase byla provedena oprava.
- $X(t)$ vysvětlující proměnná.

- Studujeme data o historii zařízení, které podléhá opotřebení.
- Když se porouchá, je nutné provést opravu.
- Poruchám se snažíme předcházet preventivní údržbou.
- T_1, \dots, T_n časy zásahů (oprav nebo údržeb).
- $\Delta_1, \dots, \Delta_n$ indikátor zda v j-tém čase byla provedena oprava.
- $X(t)$ vysvětlující proměnná.

- Chceme rozumný popis vlivu oprav, údržby a regresorů na životnost.

Data jako čítací procesy

- Zavedeme čítací procesy oprav a údržeb

$$N_{\bullet}(t) = \sum_{j=1}^n I(T_j \leq t, \Delta_j = 1), \quad M_{\bullet}(t) = \sum_{j=1}^n I(T_j \leq t, \Delta_j = 0).$$

- Označíme rizikovou funkci

$$\lambda(t) = \lim_{h \rightarrow 0} P(N_{\bullet}(t+h) - N_{\bullet}(t) \geq 1 | \mathcal{H}(t)) / h$$

kde $\mathcal{H}(t)$ značí historii událostí do času t

a kumulativní rizikovou funkci $\Lambda(t) = \int_0^t \lambda(s) ds$.

Data jako čítací procesy

- Zavedeme čítací procesy oprav a údržeb

$$N_{\bullet}(t) = \sum_{j=1}^n I(T_j \leq t, \Delta_j = 1), \quad M_{\bullet}(t) = \sum_{j=1}^n I(T_j \leq t, \Delta_j = 0).$$

- Označíme rizikovou funkci

$$\lambda(t) = \lim_{h \rightarrow 0} P(N_{\bullet}(t+h) - N_{\bullet}(t) \geq 1 | \mathcal{H}(t)) / h$$

kde $\mathcal{H}(t)$ značí historii událostí do času t

a kumulativní rizikovou funkci $\Lambda(t) = \int_0^t \lambda(s) ds$.

- Předpokládejme, že oprava sice vrátí prvek jen do stavu těsně před poruchou, ale má vliv na rizikovou funkci.
- Rizikovou funkci vhodně parametrizujeme, chceme odhadnout parametry metodou max. věrohodnosti.
- Log-věrohodnost lze přepsat jako

$$l = \sum_{j=1}^n \Delta_j \log \lambda(T_j^-) - \int_0^{T_n} \lambda(t) dt.$$

- V Coxově modelu působí regresory multiplikativně na rizikovou funkci.
- Předpokládáme, že každá oprava či údržba multiplikativně sníží nebo zvýší riziko, stejně tak případné regresory. Uvažujeme rizikovou funkci ve tvaru (Percy & Alkali 2005):

$$\lambda(t) = \lambda_0(t) e^{M_{\bullet}(t)\rho + N_{\bullet}(t)\sigma + X^T(t)\beta}.$$

- Jako vysvětlující proměnnou $X(t)$ je možné použít např. náročnost poslední opravy.
- Pokud se hodnoty kovariáty mění jen v časech událostí, je možné snadno dosadit do logaritmické věrohodnosti a při parametrickém základním riziku maximalizovat.

Model zrychleného času

- Můžeme také předpokládat, že každá oprava či údržba a regresory způsobí, že virtuální čas plyne pomaleji nebo rychleji (Accelerated Failure Time model, AFT). Využijeme transformaci času (Lin & Ying, 1995):

$$t \rightarrow \int_0^t e^{M_{\bullet}(s)\rho + N_{\bullet}(s)\sigma + X^T(s)\beta} ds =: h(t, \beta),$$

- kde jsme označili $\beta = (\rho, \sigma, \beta)$. Riziková funkce pak má tvar

$$\lambda(t) = \lambda_0(h(t, \beta)) e^{M_{\bullet}(t)\rho + N_{\bullet}(t)\sigma + X^T(t)\beta}.$$

- Pokud základní riziková funkce bude konstantní, oba modely splývají.

Inference při více pozorováních

Máme-li k dispozici data o n nezávislých zařízeních, pracujeme se sdruženou věrohodností. Můžeme:

- parametrizovat základní riziko a postupovat jako výše
- nebo odhadnout základní riziko neparametricky.

Inference při více pozorováních

Máme-li k dispozici data o n nezávislých zařízeních, pracujeme se sdruženou věrohodností. Můžeme:

- parametrizovat základní riziko a postupovat jako výše
- nebo odhadnout základní riziko neparametricky.

Mějme $\lambda_i(t)$, T_{ij} , Δ_{ij} , $j = 1, \dots, n_i$ a $X_i(t)$ rizikovou funkci, časy událostí, indikátory oprav a hodnoty regresorů i -tého prvku.

Označíme

$$N_{ij}(t) = \Delta_{ij} I(T_{ij} \leq t)$$

$$M_{ij}(t) = (1 - \Delta_{ij}) I(T_{ij} \leq t)$$

$$Y_{ij}(t) = I(T_{i,j-1} < t \leq T_{ij}).$$

Dostaneme log-věrohodnost

$$l = \sum_{ij} \int_0^{\infty} (\log \lambda_i(t^-) dN_{ij}(t) - Y_{ij}(t) \lambda_i(t^-) dt),$$

v rizikové funkci λ_i budou obsaženy počty oprav a údržeb $N_{i\bullet}$ a $M_{i\bullet}$.

Coxův model semiparametricky

- Označíme $\mathbf{X}_i(t) = (N_{i\bullet}(t), M_{i\bullet}(t), X_i(t))$.
- Skóre získané dosazením rizikové funkce do logaritmické věrohodnosti a derivováním podle parametrů ale závisí na $\Lambda_0(t)$.
- Tu můžeme nahradit Nelson-Aalenovým odhadem

$$\hat{\Lambda}_0(t, \beta) = \int_0^t \frac{dN_{\bullet\bullet}(s)}{\sum_{ij} e^{\mathbf{x}_i^T(s^-)\beta} Y_{ij}(s)}.$$

- Po dosazení získáme skóre ve tvaru

$$U(\beta) = \sum_{ij} \int_0^\infty \left(\mathbf{x}_i(t^-) - \frac{\sum_{ij} \mathbf{x}_i(t^-) e^{\mathbf{x}_i^T(t^-)\beta} Y_{ij}(t)}{\sum_{ij} e^{\mathbf{x}_i^T(t^-)\beta} Y_{ij}(t)} \right) dN_{ij}(t)$$

a pro nalezení odhadů parametrů řešíme rovnice $U(\beta) = 0$.

AFT model semiparametrický

- Pro každý prvek máme transformaci času $h_i(t, \beta)$. Zavedeme transformované procesy

$$N_{ij}^*(t, \beta) = \Delta_{ij} I(h_i(T_{ij}, \beta) \leq t), \quad M_{ij}^*(t, \beta) = (1 - \Delta_{ij}) I(h_i(T_{ij}, \beta) \leq t),$$

$$Y_{ij}^*(t, \beta) = I(h_i(T_{i,j-1}, \beta) < t \leq h_i(T_{ij}, \beta)), \quad X_i^*(t, \beta) = X_i(h_i^{-1}(t, \beta)).$$

- Přesné skóre má složitější tvar, je ale možné jej nahradit přibližným (Lin & Ying, 1995) a dosadit odhad

$$\hat{\Lambda}_0(t, \beta) = \int_0^t \frac{dN_{\bullet\bullet}^*(s, \beta)}{\sum_{ij} Y_{ij}^*(s, \beta)}.$$

- Získáme

$$U(\beta) = \sum_{ij} \int_0^\infty \left(\mathbf{X}_i^*(t^-, \beta) - \frac{\sum_{ij} \mathbf{X}_i^*(t^-, \beta) Y_{ij}^*(t, \beta)}{\sum_{ij} Y_{ij}^*(t, \beta)} \right) dN_{ij}^*(t, \beta)$$

a minimalizací $\|U(\beta)\|$ opět můžeme najít odhady parametrů.



Modelování provozu čerpadla

Máme k dispozici data o provozu ropných čerpadel za několik let (Kobbacy, 1997 a Percy, 2007):

- Pro jedno čerpadlo máme podrobnější údaje o časech údržeb, oprav a o náročnosti každého zásahu v člověkohodinách. Zkusili jsme parametrické modelování životnosti při různých základních rizikových funkcích, odhadujeme ρ , σ a β v Coxově i AFT modelu.
- Pro pět čerpadel máme k dispozici jen časy oprav a údržeb. Odhadujeme ρ a σ pomocí semiparametrických metod a porovnááme s výsledky při použití parametrizovaného základního rizika.

Výsledky viz poster.

Odhad kumulované základní rizikové funkce



Děkuji za pozornost

Reference

- [1] Kobbacy K.A.H., Fawzi B.B., Percy D.F., Ascher H.E.: *A full history proportional hazards model for preventive maintenance scheduling*, Quality and Reliability Engineering Intl. 13, 187–198, 1997.
- [2] Lin D.Y., Ying Z.: *Semiparametric inference for the accelerated life model with time-dependent covariates*, Journal of Statistical Planning and Inference 44, 47-63, 1995.
- [3] Percy D.F., Alkali B.M.: *Generalized proportional intensities models for repairable systems*, IMA Journal of Management Mathematics 17, 171-185, 2005.
- [4] Percy D.F., Alkali B.M.: *Scheduling preventive maintenance for oil pumps using generalized proportional intensities models*, International Transactions of Operational Research 14, 547-563, 2007.