

Mgr. Jan Šváb
Zobecněný lineární model a
jeho použití v povinném ručení

31.3.2006

Seminář z aktuárských věd

Slides by L^AT_EX



Zpět

Zavřít

Obsah

① Zobecněné lineární modely (GLZ¹)

- ⇒ Obecný lineární model (GLM)
- ⇒ Rozdělení exponenciálního typu
- ⇒ MLE
- ⇒ Testování hypotéz
- ⇒ Příklady

② Použití v povinném ručení

- ⇒ BMS
- ⇒ Sazby
- ⇒ Komplexní model

③ Poznámky k software

¹Zkratka používaná SW StatSoft Statistica



Zpět

Zavřít

Model

Vysvětlovaná proměnná = systematická složka + stochastická složka

⇒ y_1, \dots, y_n pozorování vysvětlované proměnné

⇒ y_i je realizací náhodné veličiny Y_i

Obecný lineární model

$$Y_i \sim N(\mu_i, \sigma^2)$$

$$\mu_i = \mathbf{x}_i' \boldsymbol{\beta}$$

⇒ p vysvětlujících proměnných $\boldsymbol{\beta} = (\beta_1, \dots, \beta_p)'$

⇒ i té pozorování $\mathbf{x}_i = (x_{i1}, \dots, x_{ip})'$



Zpět

Zavřít

Zobecněný lineární model

Obecný model zobecníme ve dvou krocích:

(μ_i je nadále střední hodnotou n. v. Y_i a β jsou vysvětlující parametry)

① **Stochastickou složku:** Y_i má rozdělení exponenciálního typu

② **Systematickou složku:**

⇒ lineární vztah mezi vysvětlujícími proměnnými a vysvětlujícími parametry

$$\eta_i = \mathbf{x}'_i \boldsymbol{\beta}$$

⇒ spojovací funkce (link)
mezi střední hodnotou μ_i a lineární složkou η_i

$$g(\mu_i) = \eta_i$$

(ryze monotónní, se spoj. druhou derivací)

Model může obsahovat jak spojité tak kategoriální vysvětlující proměnné



Zpět

Zavřít

Rozdělení exponenciálního typu

Obecná forma

$$f(y, \theta) = \exp(d(\theta)e(y) + g(\theta) + h(y))$$

Přirozená forma

$$f(y, \theta, \varphi) = \exp\left(\frac{y\theta - b(\theta)}{a(\varphi)} + c(y, \varphi)\right)$$

$d(\theta) = \theta$ a $e(y) = y$, navíc parametr φ

⇒ θ je přirozený (kanonický) parametr

⇒ φ je rozptylový (disperzní) parametr



Zpět

Zavřít

Disperzní funkce $a(\varphi)$: Používá se konstantní rovna φ nebo ve tvaru

$$a_i(\varphi) = \varphi/w_i$$

Kumulantová funkce $b(\theta)$: se spojitou druhou derivaci

$$\kappa_r = b^{(r)}(\theta)a(\varphi)^{r-1}$$

$$E[Y] = b'(\theta) = \mu$$

$$\text{Var}[Y] = b''(\theta)a(\varphi) = V(\mu)a(\varphi)$$

$\kappa(1)$ je střední hodnota a $\kappa(2), \kappa(3)$ další dva centrální momenty

Rozdělení je plně určeno vztahem mezi $E[Y]$ a $\text{Var} Y$.

$$V(\mu) = 1 \quad \text{Normální}$$

$$V(\mu) = \mu^2 \quad \text{Gamma}$$

$$V(\mu) = \mu \quad \text{Poissonovo}$$

$$V(\mu) = \mu^3 \quad \text{Inverzní Gaussovo}$$

Doplňková funkce $c(y, \varphi)$ normuje hustotu



Zpět

Zavřít

Měření tailu Míra rizika (hazard rate) na intervalu pevné šířky w

$$h_w(y) = \frac{F(y+w) - F(y)}{1 - F(y)} \quad h_w(y) = \frac{P(y < Y \leq y+w)}{P(Y > y)}$$

Interpretace: Uvažujme vrstvu w xs y .

- ⇨ h_w je prst., že škoda nepřesáhne $y + w$, pokud už přesáhla y .
- ⇨ Vysoká hodnota h_w znamená, že škoda nad y vyčerpá tuto vrstvu jen s malou prstí. = lehký tail.
- ⇨ Pro většinu aplikací v pojišťovnictví uvažujeme klesající míru rizika. $h_w(y) \rightarrow 0$ pro $y \rightarrow \infty$.
- ⇨ Normální a Poissonovo mají limitu 1
- ⇨ Negativně binomické, Gamma a Inverzní Gaussovo jdou ke konstantě mezi 0 a 1
- ⇨ Logaritmicko normální jde k nule, **ale není z exp. rodiny s hustotou v přirozeném tvaru**

Exp. rodina rozdělení je méně vhodná pro odvětví s těžším taillem.

- * transformace logaritmem a pak GLM není totéž jako GLZ s logaritmickou linkovací funkcí
- * je rozdíl mezi transformací y_i a transformací střední hodnoty

Odhad β metodou maximální věrohodnosti

Logaritmická věrohodnostní funkce

$$l(\beta) = \sum_{i=1}^n \left(\frac{Y_i \theta_i - b(\theta)}{a(\varphi)} + c(Y_i, \varphi) \right)$$

Derivace

$$\frac{\partial l}{\partial \beta} = \sum_{i=1}^n \frac{\partial l}{\partial \theta_i} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \eta_i} \frac{\partial \eta_i}{\partial \beta} = \sum_{i=1}^n \frac{1}{a_i(\varphi)} (Y_i - \mu_i) \frac{1}{V(\mu_i) g'(\mu_i)} \mathbf{x}_i = \mathbf{0}$$

Kanonický link: spojovací funkce je inverzní funkcí k b' , potom můžeme zjednodušit na soustavu nelineárních rovnic

$$\sum_{i=1}^n (Y_i - \mu_i) \mathbf{x}_i = \mathbf{0}$$

Řeší se různými iteračními metodami



Zpět

Zavřít

Iteračně vážená metoda nejmenších čtverců (IWLS, IRLS)

⇒ $\hat{\beta}$ je předchozí odhad β , dopočteme $\hat{\eta}_i = \mathbf{x}'_i \hat{\beta}$ a $\hat{\mu}_i = g_{-1}(\hat{\eta}_i)$

⇒ spočteme pracovní závislou proměnnou

$$z_i = \hat{\eta}_i + (y_i - \hat{\mu}_i) \frac{d\eta_i}{d\mu_i}$$

⇒ vypočteme iteraci vah (začínáme s w_i ze vztahu $a_i(\varphi) = \varphi/w_i$)

$$w_i^{\text{new}} = w_i / [b''(\theta_i) \left(\frac{d\eta_i}{d\mu_i}\right)^2]$$

⇒ nakonec dostaneme nový odhad β

$$\hat{\beta} = (\mathbf{X}' \mathbf{W} \mathbf{X})^{-1} \mathbf{X}' \mathbf{W} \mathbf{z}$$

Jako výchozí aproximace se volí $\hat{\mu}_i = y_i$



Zpět

Zavřít

Míry dobré shody

Plný (saturovaný) model maximalizuje věrhodnostní funkci (l^*)

V saturovaném modelu máme $\hat{\mu}_i^* = y_i$ a $\hat{\theta}_i^* = (b')_{-1}(y_i)$

škálovatelná deviance (log věr. fce modelu vs. její max hodnota)

$$D^*(\hat{\beta}) = 2 \left(l^* - l(\hat{\beta}) \right) = 2 \sum_{i=1}^n \frac{1}{a_i(\varphi)} \left(y_i \left(\hat{\theta}_i^* - \hat{\theta} \right) - \left(b(\hat{\theta}_i^*) - b(\hat{\theta}) \right) \right)$$

deviance (při $a_i(\varphi) = \varphi/w_i$)

$$D(\hat{\beta}) = D^*(\hat{\beta})\varphi = 2 \sum_{i=1}^n w_i \left(y_i \left(\hat{\theta}_i^* - \hat{\theta} \right) - \left(b(\hat{\theta}_i^*) - b(\hat{\theta}) \right) \right)$$

Pearsonovo χ^2 (pozorování vs. odhadem jejich střední hod. v modelu)

$$\chi^2 = \sum_{i=1}^n \frac{(y_i - \hat{\mu}_i)^2}{V(\hat{\mu}_i)}$$



Zpět

Zavřít

Testování podmodelu

⇒ Označme $\bar{\beta}$ odhad β v podmodelu s $p' < p$ parametry

$$l(\hat{\beta}) - l(\bar{\beta}) = D^*(\hat{\beta}) - D^*(\bar{\beta}) = \frac{D(\hat{\beta}) - D^*(\bar{\beta})}{\varphi} \stackrel{as}{\sim} \chi_q^2,$$

kde $q = p - p'$ je rozdíl v počtu parametrů, při známém φ

⇒ Waldův test

$$I(\beta) = \mathbf{X}'\mathbf{W}\mathbf{X} / \varphi$$

$$\hat{\beta} \stackrel{as}{\sim} N_p(\beta, (\mathbf{X}'\mathbf{W}\mathbf{X})^{-1}\varphi)$$

Testy podmnožin β jsou založeny na příslušných marginálních rozděleních

⇒ konzistentní statistika pro odhad parametru φ

$$\hat{\varphi} = \frac{D(\hat{\beta})}{n - p}$$



Zpět

Zavřít

Příklady GLZ

- ⇒ Obecný lineární model, Normální rozdělení, identita
- ⇒ Log lineární model, Poissonovo rozdělení, logaritmus
- ⇒ Gamma regrese, Gamma rozdělení, reciprocita
- ⇒ Logistický model, Binomické rozdělení, logitová funkce

Další rozdělení:

- ⇒ Inverzní Gaussovo
- ⇒ Negativně binomické
- ⇒ „overdispersed“ Poissonovo rozdělení
- ⇒ Logaritmicko normální **NE**, jen v obecné formě

Další modely:

- ⇒ probitový model, log log model



Zpět

Zavřít

Obecný lineární model

Normální rozdělení $Y_i \sim N(\mu_i, \sigma^2)$: $f(y_i) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y_i - \mu_i)^2}{2\sigma^2}\right)$

⇒ Přirozený parametr $\theta_i = \mu_i$ a rozptylová funkce $V(\mu_i) = 1$

⇒ $a(\varphi) = \varphi = \sigma^2$ $b(\theta_i) = \mu^2/2$ $c(y_i, \varphi) = -\frac{y_i^2}{2\sigma^2} - \frac{1}{2} \log(2\pi\sigma^2)$

⇒ kanonický link: $\mu_i = \eta_i$

⇒ IWLS: $z_i = \eta_i + (y_i - \mu_i) = y_i \Rightarrow \hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$
výsledek v prvním kroku

⇒ deviance je reziduální součet čtverců

$$D = \varphi D^* = \sum_{i=1}^n (y_i - \hat{\mu}_i)^2$$



Zpět

Zavřít

Log lineární model

Poissonovo rozdělení $Y_i \sim Po(\mu_i)$: $f(y_i) = \frac{e^{-\mu_i} \mu_i^{y_i}}{y_i!}$

⇒ Přírozený parametr $\theta_i = \log \mu_i$ a rozptylová funkce $V(\mu_i) = \mu_i$

⇒ $a(\varphi) = \varphi = 1$ $b(\theta_i) = e^{\theta_i}$ $c(y_i, \varphi) = -\log(y_i!)$

⇒ kanonický link: $\eta_i = \log(\mu_i)$

⇒ IWLS: $z_i = \eta_i + (y_i - \mu_i)/\mu_i$ a iterované váhy $w_i = \mu_i$

⇒ deviance

$$D = 2 \sum_{i=1}^n \left(y_i \log \frac{y_i}{\hat{\mu}_i} - (y_i - \hat{\mu}_i) \right)$$

⇒ $\sum Y_i \sim Po(\sum \mu_i)$

$$D = 2 \sum_{i=1}^n \left(y_i \log \frac{y_i}{\hat{\mu}_i} \right)$$



Zpět

Zavřít

Použití GLZ v povinném ručení

- ⇒ BMS
- ⇒ Sazby
- ⇒ Komplexní model



Zpět

Zavřít

Model v povinném ručení

Y je modelovaná kvantita (výše škody, agregace, počet), závisí na

⇒ $X = \{X_1, X_2, \dots\}$, apriorní tarifní proměnné - grupování rizik

⇒ $Z = \{Z_1, Z_2, \dots\}$, neznámé proměnné

Rizikové faktory pojistníka jsou $\Omega = X \cup Z$.

Pojistné $E[Y|\Omega]$

	Nese pojistník	Nese pojistitel
Riziko	$E[Y \Omega]$	$Y - E[Y \Omega]$
Střední hodnota	EY	0
Rozptyl	$\text{Var}[E[Y \Omega]]$	$E[\text{Var}[Y \Omega]]$

Předchozí situace je čistě teoretická, neboť neznáme Z .

Riziko	$E[Y X]$	$Y - E[Y X]$
Střední hodnota	$E[Y]$	0
Rozptyl	$\text{Var}[E[Y X]]$	$E[\text{Var}[Y X]]$



Zpět

Zavřít

Aposteriorní sazbování

- ⇒ Minulá škodní zkušenosti o riziku Y , označme Y^{\leftarrow}
- ⇒ Ω a (X, Y^{\leftarrow}) s stávají porovnatelné, jak čas běží
- ⇒ Potom máme pojistné

$$E[Y|X, Y^{\leftarrow}]$$

Možnosti konstrukce modelu:

- ① Uvažujeme klasifikaci rizika a BMS odděleně
- ② Uvažujeme komplexní model klasifikující riziko a zahrnující BMS

Příklad: Španělská pojišťovna 4 x 3 tříd



Zpět

Zavřít

System bonus-malus (BMS)

- ⇒ Riziko i je reprezentováno $(\Theta_i, K_{i1}, K_{i2}, \dots)$
- ⇒ Počty škod v čase $K_{ij} | \Theta_i = \theta \sim Po(\theta)$ a podmíněně nezávislé
- ⇒ $\Theta_i \sim \Gamma(a, \tau)$ (K_{ij} má nepodmíněné rozdělení negativně binomické)
- ⇒ Označme $K_{i\bullet}(t) = \sum_{j=1}^t K_{ij}$
- ⇒ Uvažujme jednotkovou očekávanou výši škody
- ⇒ Apriori bez historie je požadováno pojistné $E[\Theta_i]$
- ⇒ Pojistné určíme minimalizací $E[L(\theta_i - \Psi(k_{i1}, \dots, k_{it}))]$

$$L(x) = x^2 \quad \Rightarrow \quad W_{t+1}^q = \frac{a}{\tau}(1 - \rho_q) + \frac{k_{i\bullet}(t)}{t} \rho_q$$

$$L(x) = \exp(-cx) \quad \Rightarrow \quad W_{t+1}^e = \frac{a}{\tau}(1 - \rho_e(c)) + \frac{k_{i\bullet}(t)}{t} \rho_e(c)$$

kde $\rho_q = \frac{t}{\tau+t}$ a $\rho_e(c) = \frac{t}{c} \log\left(1 + \frac{c}{\tau+t}\right)$

$$L(x) = x^2 \quad \Rightarrow \quad W_{t+1}^q = \frac{a}{\tau}(1 - \rho_q) + \frac{k_{i\bullet}(t)}{t}\rho_q$$

$$L(x) = \exp(-cx) \quad \Rightarrow \quad W_{t+1}^e = \frac{a}{\tau}(1 - \rho_e(c)) + \frac{k_{i\bullet}(t)}{t}\rho_e(c)$$

$$\rho_q = \frac{t}{\tau+t} \quad \rho_e(c) = \frac{t}{c} \log\left(1 + \frac{c}{\tau+t}\right)$$

⇒ $\rho_e(c) \leq \rho_q$ a $W_{t+1}^e \rightarrow W_{t+1}^q$ při $c \rightarrow 0$

⇒ $\rho_e(c) \rightarrow 0$ pro $c \rightarrow \infty$, proto $W_{t+1}^e \rightarrow a/\tau$

⇒ Pojistné rizika i , které je v roce t zařazeno v třídě $I_i(t)$

$$P_{t+1}^{q,e}(k_{i\bullet}(t), t) = BP_{I_i(t+1)} BMF_{t+1}^{q,e}(k_{i\bullet}(t), t),$$

$$\Rightarrow BMF^q(k_{i\bullet}(t), t) = \frac{W_{t+1}^q}{E[\Theta]_i} = \frac{a+k_{i\bullet}(t)}{\tau+t} \frac{\tau}{a}$$

$$\Rightarrow BMF^e(k_{i\bullet}(t), t) = \frac{W_{t+1}^e}{E[\Theta]_i} = 1 - \frac{t}{c} \log\left(1 + \frac{c}{\tau+t}\right) + \log\left(1 + \frac{c}{\tau+t}\right) \frac{k_{i\bullet}(t)}{c} \frac{\tau}{a}$$



Zpět

Zavřít

Výsledky: BMS - odhady v Negativně binomickém rozdělení

$$\hat{a} = 0.8665 \text{ a } \hat{\tau} = 3.9097$$

k	n_k	\hat{n}_k	$n_k - \hat{n}_k$
0	122 628	122 713	-85
1	21 686	21 656	30
2	4 014	4 116	-102
3	832	801	31
4	224	158	66
5	68	31	37
6	17	6	11
7	7	1	6
8	7	0	7
≥ 9	0	0	0



Zpět

Zavřít

Pozorované ŠF

Výkon	Věk		
	≤ 35	$35 < \bullet \leq 49$	≥ 50
≤ 53	0.1866	0.1572	0.1283
$53 < \bullet \leq 75$	0.2685	0.2279	0.1986
$75 < \bullet \leq 118$	0.2992	0.2526	0.2386
≥ 118	0.3217	0.2846	0.2483

- ⇒ Kategorické proměnné pro věk J_2, J_3 a pro výkon L_2, L_3, L_4
- ⇒ Každá třída je reprezentována vektorem $\mathbf{x}_i = (1, j_2, j_3, l_2, l_3, l_4)$
- ⇒ Parametry $\boldsymbol{\beta} = (\epsilon, \gamma_2, \gamma_3, \delta_2, \delta_3, \delta_4)$
- ⇒ Log lineární model, Poissonovo rozdělení, logaritmický link



Zpět

Zavřít

Výsledky:


Parametr	Odhad	sm. odch.
ϵ	-1.7219	0.0198
γ_2	-0.1634	0.0147
γ_3	-0.2800	0.0149
δ_2	0.3987	0.0185
δ_3	0.5324	0.0189
δ_4	0.6150	0.0236

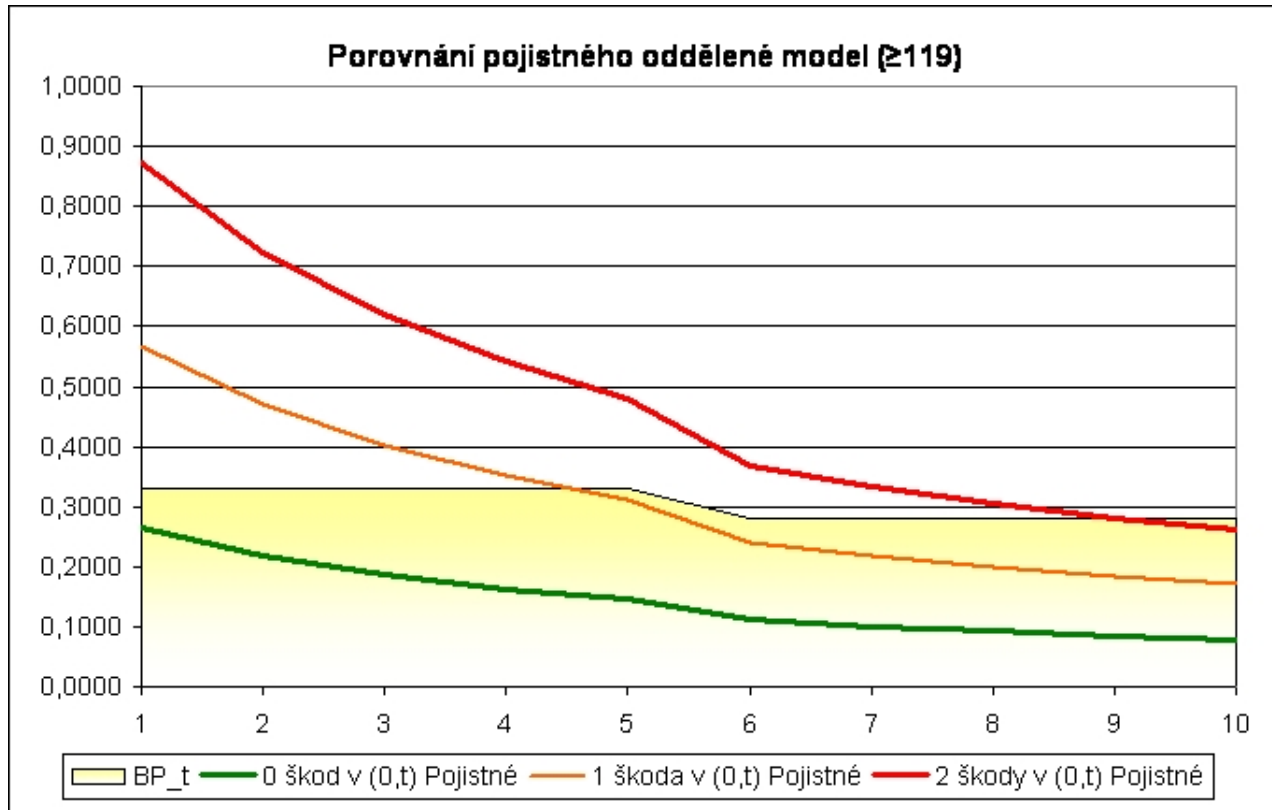
Výkon	Věk		
	≤ 35	$35 < \bullet \leq 49$	≥ 50
≤ 53	0.1787	0.1518	0.1351
$53 < \bullet \leq 75$	0.2663	0.2262	0.2013
$75 < \bullet \leq 118$	0.3044	0.2585	0.2300
≥ 118	0.3306	0.2808	0.2498



Zpět

Zavřít





Komplexní model

- ⇒ Nechť je $K_{it} \sim Po(\lambda_{I_i(t)})$ počet škod rizika i v roce t , kde $I_i(t)$ je příslušný index třídy a $\lambda_{I_i(t)}$ jsou jejich ŠF
- ⇒ Rozptyl pozorování je však větší než střední hodnota, předpoklad Poissona není korektní
- ⇒ Raději předpokládáme $K_{it} \sim Po(\lambda_{I_i(t)}\Theta_i)$, kde $\Theta_i \sim \Gamma(\alpha, \alpha)$
- ⇒ Potom $K_{it}|I_i(t)$ má negativně binomické rozdělení

$$P(K_{it} = k | I_i(t)) = \binom{\alpha + k - 1}{k} \left(\frac{\lambda_{I_i(t)}}{\alpha + \lambda_{I_i(t)}} \right)^k \left(\frac{\alpha}{\alpha + \lambda_{I_i(t)}} \right)^\alpha$$

- ⇒ $\Theta_i | K_{i1} = k_{i1}, \dots, K_{it} = k_{it} \sim \Gamma(\alpha + k_{i\bullet}(t), \alpha + \lambda_{i\bullet}(t))$

- ⇒ Parametr α odhadneme metodou maximální věrohodnosti

$$L(\alpha) = \prod_{i=1}^{12} \prod_{k=0}^{k_{\max}^{(i)}} \left\{ \binom{\alpha + k - 1}{k} \left(\frac{\lambda_{I_i(t)}}{\alpha + \lambda_{I_i(t)}} \right)^k \left(\frac{\alpha}{\alpha + \lambda_{I_i(t)}} \right)^\alpha \right\}^{n_{ik}}$$

⇒ Pojistné

$$P_{t+1}^{q,e} = \lambda_{I_i(t+1)} B M F_{t+1}^{q,e}(k_{i\bullet}(t), \lambda_{i\bullet}(t))$$

⇒ Relativní výše bonusu—malusu

$$B M F_{t+1}^{q,e}(k_{i\bullet}(t), t) = (1 - \rho_{q,e}) + \rho_{q,e} \frac{k_{i\bullet}(t)}{\lambda_{i\bullet}(t)}$$

⇒ Váhy pro kvadratickou a exponenciální ztrátovou funkci

$$\rho_q = \frac{\lambda_{i\bullet}(t)}{\alpha + \lambda_{i\bullet}(t)} \quad \rho_e(c) = \frac{\lambda_{i\bullet}(t)}{c} \log \left(1 + \frac{c}{\alpha + \lambda_{i\bullet}(t)} \right)$$

⇒ Nerovnosti a konvergence stejně jako v oddělených modelech

⇒ $\rho_e(c) \leq \rho_q$

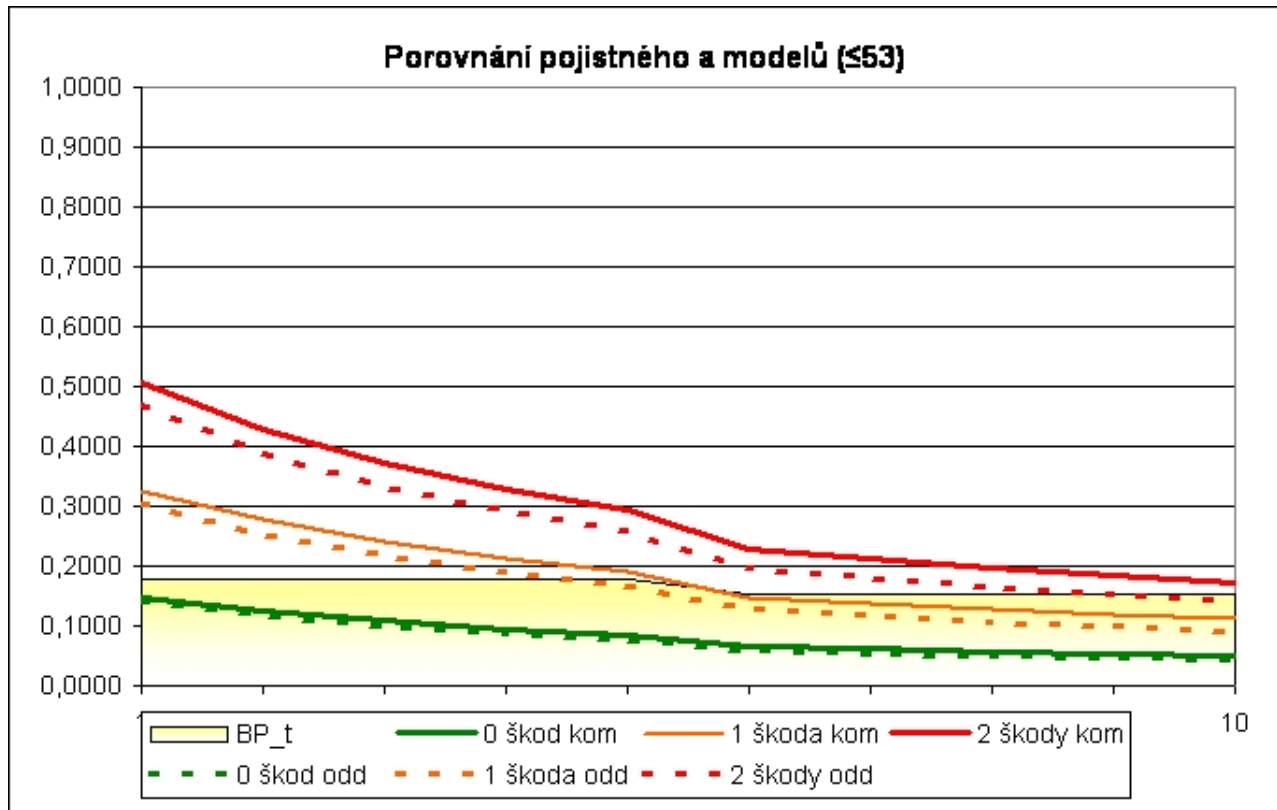
⇒ $\rho_e(c) \rightarrow \rho_q$ pro $c \rightarrow 0$ a tedy $P_{t+1}^e(k_{i\bullet}, \lambda_{i\bullet}(t)) \rightarrow P_{t+1}^q(k_{i\bullet}, \lambda_{i\bullet}(t))$

⇒ $\rho_e(c) \rightarrow 0$ pro $c \rightarrow \infty$, proto $P_{t+1}^e(k_{i\bullet}, \lambda_{i\bullet}(t)) \rightarrow \lambda_{I_i(t)}$, to znamená, že všechna rizika jedné třídy platí stejné pojistné, tj. nemáme BMS




Zpět

Zavřít



Zpět

Zavřít



Zpět

Zavřít

Poznámky k SW

Statistica

- ⇒ sigma parametrizace $\{-1, 1\}$
- ⇒ váhy pozorování
- ⇒ konstrukce modelu

Statistica

- ⇒ ukázka



Zpět

Zavřít

Literatura

- ⇒ **L. Bermúdez, M. Denuit & J. Dhaene (2001)**
Exponential bonus-malus systems integrating a priori risk classification. Journal of Actuarial Practice 9, 84-112.

Děkuji za pozornost



Zpět

Zavřít